



ISBN 978-953-95130-7-6



9 789539 513076

Tomislav Malvić, Marko Cvetković

NEURONSKI ALATI U GEOLOGIJI LEŽIŠTA UGLJIKOVODIKA

II. izdanje

Manualia Universitatis studiorum Zagabiensis – Udžbenici Sveučilišta u Zagrebu

Tomislav Malvić, Marko Cvetković

NEURONSKI ALATI U GEOLOGIJI LEŽIŠTA UGLJIKOVODIKA

II. izdanje

Hrvatsko geološko društvo

Geomatematički odsjek



Sveučilište u Zagrebu

Rudarsko-geološko-naftni fakultet



MANUALIA UNIVERSITATIS STUDIORUM
ZAGRABIENSIS

UDŽBENICI SVEUČILIŠTA U ZAGREBU



Tomislav Malvić, Marko Cvetković

NEURONSKI ALATI U GEOLOGIJI LEŽIŠTA UGLJIKOVODIKA

II. izdanje



Hrvatsko geološko društvo



Geomatematici odsjek



Sveučilište u Zagrebu



RGNF

Rudarsko-geološko-naftni fakultet

Zagreb, 2013.

Odlukom Senata Sveučilišta u Zagrebu od 10. prosinca 2013. (dopis klasa: 032-01/13-01/53, ur. broj: 380-061/160-13-2) knjiga je prihvaćena kao sveučilišni priručnik (*Manualia Universitatis studiorum Zagabiensis – Udzbenici Sveučilišta u Zagrebu*).

Nakladnici

Hrvatsko geološko društvo, Sachsova 2, Zagreb, www.geologija.hr

Rudarsko-geološko-naftni fakultet, Pierottijeva 6, Zagreb, www.rgn.hr

Za nakladnika

Dr. sc. Jasenka Sremac, izv. prof., predsjednica Hrvatskoga geološkoga društva

Dr. sc. Vesnica Garašić, doc., predsjednica Povjerenstva za sveučilišno-nastavnu literaturu RGN fakulteta

Autori

Dr. sc. Tomislav Malvić, izv. prof., znanstveni savjetnik, dipl. ing. geologije
Marko Cvetković, dipl. ing. geologije

Recenzenti

Dr. sc. Josipa Velić, red. prof., dipl. ing. geologije

(*Sveučilište u Zagrebu, Rudarsko-geološko-naftni fakultet*)

Dr. sc. Zoran Peh, znanstveni savjetnik, dipl. ing. geologije
(*Hrvatski geološki institut*)

Lektorica

Dr. sc. Ivana Matas Ivanković, znanstvena suradnica, prof.

Tisk

Denona d.o.o., Zagreb

Naklada

300 primjeraka

CIP zapis dostupan u računalnome katalogu Nacionalne i sveučilišne knjižnice u Zagrebu pod brojem 6164121. ISBN 978-953-95130-7-6.

SADRŽAJ

PREDGOVORI

IX

1. OSNOVNA IDEJA I NAČIN RADA NEURONSKE MREŽE	1
1.1. LJUDSKI NEURONI	2
1.2. STRUKTURA NEURONSKE MREŽE	4
1.3. OSNOVNI MATEMATIČKI IZRAZI NEURONSKE MREŽE	6
1.4. UČENJE MREŽE	8
1.5. MREŽA S POV RATNIM POSTUPKOM	12
1.6. MREŽA S RADIJALNOM FUNKCIJOM	16
1.7. MREŽA S POSTUPKOM POOPĆENE REGRESIJE	18
1.8. LITERATURA	20
2. PREDVIĐANJE KLASTIČNIH FACIJESA NEURONSKOM MREŽOM, PRIMJER POLJA OKOLI	21
2.1. OSNOVNI GEOLOŠKI ODNOSI U POLJU OKOLI	21
2.2. PROGRAM cVision	24
2.3. VRSTA UPOTRIJEBLJENE MREŽE I REZULTATI	25
2.3.1. Uvježbavanje mreže i njezini izlazi	26
2.3.2. Rezultati analize facijesa u polju Okoli (ležište „c ₂ “)	27
2.4. ZAKLJUČAK O UPOTREBI NEURONSKIH MREŽA U PREDVIĐANJU FACIJESA	32
2.5. LITERATURA	34
3. PREDVIĐANJE LITOLOŠKOGA SASTAVA I INTERVALA ZASIĆENIH UGLJKOVODICIMA, PRIMJER POLJA KLOŠTAR	37
3.1. OSNOVNI GEOLOŠKI ODNOSI U POLJU KLOŠTAR	37
3.2. ANALIZE NEURONSKIM MREŽAMA U POLJU KLOŠTAR	38
3.2.1. Predviđanje litološkoga sastava	39
3.2.2. Predviđanje zona zasićenih ugljikovodicima	43

3.3. MOGUĆI PROBLEMI PRILIKOM ANALIZA NEURONSKIM MREŽAMA ZAPAŽENI U PRIMJERU POLJA KLOŠTAR	45
3.4. ZAKLJUČAK O UPOTREBI NEURONSKIH MREŽA U PREDVIĐANJU LITOLOŠKOGA SASTAVA I ZASIĆENJA UGLJIKOVODICIMA	47
3.5. LITERATURA	48
4. PROCJENA ŠUPLJKAVOSTI NEURONSKOM MREŽOM, PRIMJER POLJA BENIČANCI	49
4.1. OSNOVNI GEOLOŠKI ODNOSI U POLJU BENIČANCI	51
4.2. ULAZNE VARIJABLE ZA NEURONSKU MREŽU	52
4.3. VRSTA I PARAMETRI UVJEŽBAVANJA NEURONSKE MREŽE	53
4.3.1. Vrijednosti robusnih parametara mreže	53
4.3.2. Vrijednosti osjetljivih parametara mreže	54
4.4. REZULTATI NEURONSKE MREŽE	55
4.5. ZAKLJUČAK O UPOTREBI NEURONSKIH MREŽA U PREDVIĐANJU ŠUPLJKAVOSTI	57
4.6. LITERATURA	59
5. REKONSTRUKCIJA DIJELOVA KAROTAŽNIH KRIVULJA POMOĆU NEURONSKIH MREŽA, PRIMJER IZ HRVATSKOGA DIJELA PANONSKOGA BAZENSKOGA SUSTAVA	61
5.1. OSNOVNI GEOLOŠKI ODNOSI U POLJU ĐELETOVCI	62
5.2. OSNOVNI GEOLOŠKI ODNOSI U POLJU STARI GRADAC– –BARCS NYUGAT	63
5.3. REKONSTRUKCIJA KRIVULJA NEURONSKOM MREŽOM U POLJU KLOŠTAR	64
5.3.1. Rezultati analiza višeslojne neuronske mreže	65
5.3.2. Rezultati analiza neuronske mreže s radijalnom funkcijom	68
5.3.3. Rezultati analiza neuronske mreže s postupkom poopcene regresije	70
5.4. REKONSTRUKCIJA KRIVULJA NEURONSKOM MREŽOM U POLJU STARI GRADAC–BARCS NYUGAT	72
5.4.1. Rezultati analize podataka iz intervala „miocenski klastiti”	73

5.4.2. Rezultati analize podataka iz intervala „metavulkaniti”	75
5.5. REKONSTRUKCIJA KRIVULJA NEURONSKOM MREŽOM U POLJU ĐELETOVCI	78
5.6. ZAKLJUČAK O REKONSTRUKCIJI KAROTAŽNIH KRIVULJA POMOĆU NEURONSKIH MREŽA	81
5.7. LITERATURA	82
 <i>POGOVOR</i>	83
 <i>KAZALO</i>	87

PREDGOVORI II. IZDANJU

Neuronski alati kao računalna pomagala u sve su većoj uporabi zadnjih nekoliko desetljeća. Simulirajući način razmišljanja i donošenja odluka razumnih bića, mogu se primijeniti u gotovo svim područjima prirodnih, tehničkih i društvenih znanosti. U geologiji su zauzeli osobito mjesto u procjeni veličine i položaja ležišta vrijednih sirovina, prije svega ugljikovodika, a pokazali su se korisnim i u drugim područjima geologije u kojima se primjenjuju statističke metode analize podataka. Hrvatski geolozi primjenjuju ova istraživanja od 2006. godine, a svoja iskustva razmjenjuju kroz djelovanje Geomatematickoga odsjeka Hrvatskoga geološkoga društva. Senat Sveučilišta u Zagrebu prepoznao je znakovitost prikupljenih podataka te se pred Vama nalazi drugo izdanje knjige „Neuronski alati u geologiji ležišta ugljikovodika“ autora Tomislava Malvića i Marka Cvetkovića s oznakom sveučilišnoga udžbenika. Autorima čestitamo na postignutome uspjehu, želimo im još puno vrijednih dostignuća u znanstvenome i stručnome radu, a posebno nas raduje činjenica da su studenti geologije dobili još jedan koristan nastavni materijal na našemu lijepome hrvatskome jeziku.

Prof. dr. sc. Jasenka Sremac

Nakon četiri godine i uglavnom raspodijeljene naklade I. izdanja razmišljali smo kako se u tome razdoblju promjenila uloga neuronskih mreža kao alata u geologiji i geomatematici. Činjenica je da se one i danas koriste, vjerojatno i više nego 2009. godine, i to uglavnom kroz programske pakete koji podržavaju i takve module. Tijekom nekoliko zadnjih godina možda je pri tome najveći iskorak načinjen u analizi karotažnih mjerena i litologije kvartarnih naslaga hrvatskoga dijela Panonskoga bazenskog sustava. U istome razdoblju neuronski alati postali su standardno gradivo na doktorskome kolegiju Rudarsko-geološko-naftnoga fakulteta pod nazivom „Geomatematika”. Stoga nam je drago da su Senat Sveučilišta u Zagrebu, a poglavito naši recenzenti, prepoznali vrijednost ove knjige kao dopunske literature u izučavanju toga gradiva i dodijelili joj naziv sveučilišnoga priručnika. Nadamo se kako će i ovo, drugo izdanje knjige „Neuronski alati u analizi ležišta ugljikovodika” u nakladi Hrvatskoga geološkoga društva i Rudarsko-geološko-naftnoga fakulteta naći put do velikoga broja čitatelja.

Autori

PREDGOVOR I. IZDANJU

Neuronski alati danas su ubičajeni u analizi različitih podataka, a pozornost privlače i svojim nazivom koji ih povezuje s ljudskim postupcima, odnosno mehanizmima kojima razmišljamo i odlučujemo. Već nekoliko desetljeća neuronski se alati razvijaju i teorijski i praktičnom primjenom u mnogim znanostima poput geologije, brojnih prirodnih znanosti, informatike, lingvistike, ekonomije i drugih.

Njihova je glavna primjena pri traženju zavisnosti između podataka koji nisu u isključivo linearnoj vezi, a opet mogu se ujediniti u jedan složeni ulazni skup. Ujedinjavanje takvih podataka zadatak je stručnjaka u području u kojem se neuronske mreže primjenjuju, a njihova analiza kasnije je u domeni vrste neuronske mreže koja je odabrana. Danas postoji nekoliko glavnih vrsta mreža, a o njima će više riječi biti u tekstu knjige. No, temeljno je obilježje svih mreža da se odlikuju svojstvom „učenja”, tj. uvježbavanja kroz niz ponavljačih postupaka analize. Od cijelog skupa podataka veći dio upotrijebljen je za učenje, a manji za ponovno predviđanje poznatih vrijednosti. Na taj način lako je izračunati pogrešku predviđanja, koja bi s većim brojem pokušaja trebala biti što manja. Taj postupak „učenja” nalik je na ljudsko učenje iz iskustva pa odatle i naziv „neuronske mreže”.

Primjena takvih alata u geologiji prilično je raširena, a posebno u onim disciplinama u kojima se raspolaze velikim brojem podataka te se kod većine analiza upotrebljavaju namjenski računalni programi. Geologija ležišta ugljikovodika jedna je od takvih disciplina unutar polja geologije u kojoj autori imaju prilično iskustvo pa se primjeri upotrebe neuronskih alata odnose upravo na analize podataka iz ležišta nafte i plina.

No, svi su primjeri vrlo razumljivi te je, uz malo truda, gotovo jednake neuronske modele moguće preslikati u sva druga područja geologije, odnosno prikupljene stratigrafske, tektonske, hidrogeološke, inženjersko geološke i druge podatke analizirati neuronskim alatima.

Nadamo se da će čitateljima knjiga koja je pred njima biti zanimljiva, laka za snalaženje te im pružiti dovoljno znanja da samostalno načine različita predviđanja, rekonstrukcije i procjene na temelju svojih podataka upotrebom neuronskih alata.

Autori

1. OSNOVNA IDEJA I NAČIN RADA UMJETNE NEURONSKE MREŽE

Umjetna neuronska mreža ima dosta dodirnih točaka s ljudskom moždanom strukturom. Ta sličnost nije izražena u gradivnim elementima tih mreža, jer je, naravno, ljudska neuronska struktura biološka, sastavljena od stanica u kojima se informacije prenose kemijskim i električnim putom. Za razliku od toga, umjetna (računalna) neuronska mreža temelji se na poluvodičkoj tehnologiji u kojoj se promjene stanja unutar mikroprocesora prenose isključivo električki. Zajedničko im je da obje vrste mreža prenose samo dvije informacije, tj. je li veza aktivna (1) ili nije (0), koje su izražene određenim električnim potencijalom, bilo u mozgu, bilo u računalu.

Sličnost je tih dviju mreža u načinu kako ta dva stanja upotrebljavaju da bi konačan rezultat predstavlja suvislu obradbu podataka. Obje arhitekture na kraju se temelje na postupcima koji se ponavljaju, iteracijama, ili učenju, odnosno uvježbavanju (npr. **Rosenblatt, 1957, 1958**). Ovisno o malim promjenama u rezultatima kod svake iteracije dolazi do korekcije konačnoga rezultata koji se na kraju procesa učenja spremi kao završni Dobiveni uzorak (pod uzorkom se misli na konačnu arhitekturu mreže i završni matematički izraz za daljnju procjenu) upotrebljava se za kasniju analizu istovrsnih ili sličnih podataka (situacija) te se kod čovjeka naziva *iskustvom*, a kod računala *uvježbanom mrežom*. Osnovne računalne arhitekture neuronskih računalnih mreža dane su

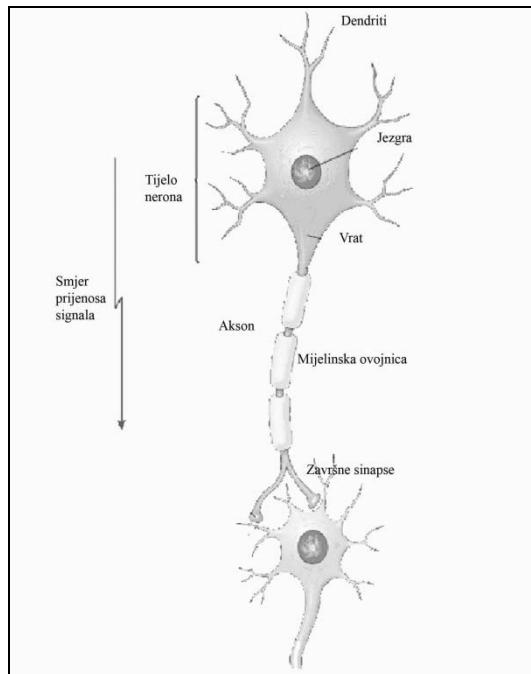
u sljedećim potpoglavlјima s naglaskom da su te temeljne postavke nadograđene kroz niz posebnih postupaka, odnosno posebnih vrsta neuronskih mreža nastalih prilagodavanjem obradba za odredene skupove podataka, a nakon što je prikupljeno znatno iskustvo o ponašanju osnovnih tipova mreža (npr. **Anderson & Rosenfeld, 1989; McCormack, 1991; Riedmiller & Braun, 1993**).

1.1. LJUDSKI NEURONI

U ljudskome mozgu neuroni služe kao prijenosnici informacija međusobno komunicirajući sinapsama. Ovisno o vrsti poslanoga signala susjedni će se neuron aktivirati ili će ostati neaktivan. Skup mnoštva takvih međudjelovanja čini ono što se naziva „mišljenje”. Takav mehanizam izgleda vrlo jednostavno dok se ne uzme u obzir podatak da u mozgu ima oko 10^{11} neurona. Svaki od njih povezan je s gotovo tisuću susjednih neurona. Tijelo neurona (**slika 1.1**) naziva se *soma*. Okruženo je *dendritima* koji primaju signale iz ostalih neurona. Ti signali mogu potaknuti ili spriječiti daljnju neuronsku aktivnost. Ako je neuron aktiviran, stvara se električni impuls koji polazi od baze izlaza neurona (engl. *hillock*), kreće se preko nastavaka nazvanih *aksonima* (engl. *axon*) i završava na krajevima sinapse (engl. *boutons*).

Ako je ljudski neuron aktiviran, znači da je nastao električni impuls koji se prenosi elektrokemijskim putom preko sinapsa. Gledano fizikalno, „neaktivni” neuroni imaju električni potencijal 40 – 60 mV. „Aktivnim” neuronima potencijal se mijenja na 90 – 100 mV. Brzina putovanja impulsa iznosi 0,5 – 100 m/s i obično traje oko 1

ms (znači da signal u prosjeku prelazi put od 5 do 10 cm). Nakon aktiviranja neurona treba proteći nekoliko milisekunda da bi se mogao ponovno aktivirati. Općenito, prosječni neuron može se aktivirati oko 100 puta u sekundi ili jedanput u 10 ms.



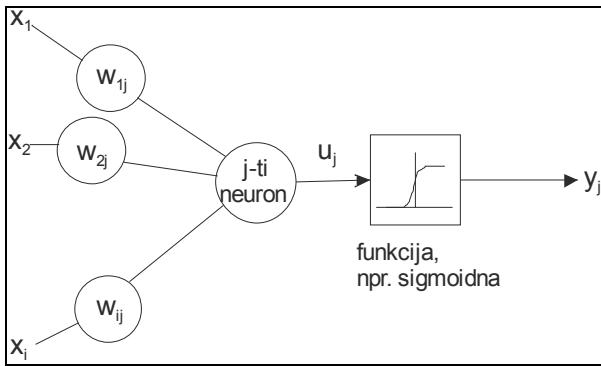
Slika 1.1: Model ljudskoga neurona

Kod električnog računala brzina signala iznosi oko 3×10^8 m/s, trajanje je električnoga impulsa 10^{-5} ms. Vidljivo je da računala oko 3×10^{11} puta brže prenose električni signal. Uz to, njihovo je vrijeme „oporavka“ oko milijun puta kraće od ljudskih neurona ili oko 10 ns. Brzina prijenosa podataka očito je za nekoliko redova veličine na strani računala, no to nije jedini kriterij ocjene sustava, jer bi u

tome slučaju elektroničko računalo već sada bilo nedostižno ljudskom mozgu. Budući da to nije tako, očito je trebalo pronaći i definirati način kojim čovjek dominira u odnosu na svoje elektroničko djelo. I ta je prednost izražena u iznimnoj sposobnosti prepoznavanja uzorka (pravilnosti) u svojem okruženju te donošenju zaključaka iz samo dijela podataka koji su ranije obrađeni. Drugim riječima, ljudski um ima sposobnost učenja i pamćenja, ali i mogućnost korekcije svojih zaključaka na temelju iskustva. Cilj je neuronskih mreža stvoriti uzorak što sličniji ljudskomu pamćenju, učenju i iskustvu unutar računalnoga sustava.

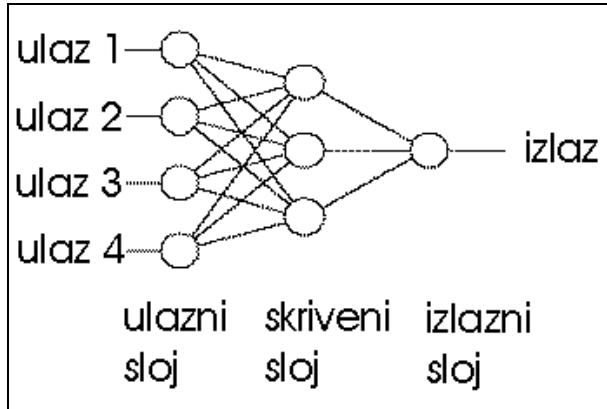
1.2. STRUKTURA NEURONSKE MREŽE

Struktura neuronske mreže temelji se na modelu umjetnoga neurona (**slika 1.2**). Takav neuron sastavljen je od nekoliko ulaza i jednoga izlaza. Svakomu ulazu dodijeljena je odgovarajuća težina kojom se opterećuje ulazna vrijednost. Ovisno o rezultatu, neuron će ostati neaktiviran ili će se aktivirati. O vrijednostima i uvjetima aktivacije odlučuje tzv. aktivacijska funkcija. Neuronska mreža ima još jedno obilježje kojim opomaša rad ljudskog mozga, a to je povrat informacije te se na taj način se ostvaruje nešto što nalikuje na učenje. Taj postupak opisuje jedan od najčešćih modela neuronskih mreža, tj. mrežu s povratnim postupkom (engl. *backpropagation network*).



Slika 1.2: Model umjetnoga neurona

Način na koji određeni broj neurona čini mrežu mogao bi se opisati pomoću nekoliko vrsta slojeva (**slika 1.3**). Prvo se odabrani broj neurona poreda u niz čineći ulazni sloj. Ti neuroni svoje signale šalju prema međuslojevima koji nemaju vezu s okolinom (ni ulaznu, ni izlaznu) te su nazvani i skriveni slojevi. Način veze između ulaznoga i tih slojeva određuje vrstu mreže, a mreža je obično potpuno povezana unatrag, što znači da je svaki neuron povezan sa svakim izlazom iz prethodnoga sloja. Rezultat je, nakon obradbe, uvijek izražen kroz jedan izlazni sloj koji je veza prema vanjskome svijetu.



Slika 1.3: Shema organizacije neuronske mreže preko slojeva

Općenito, ulazni sloj prosljeđuje signal iz okolnoga svijeta. Skriveni slojevi obrađuju primljeni signal. Izlazni sloj prikuplja rezultate i stvara izlaz.

1.3. OSNOVNI MATEMATIČKI IZRAZI NEURONSKE MREŽE

Izlaz svakoga neurona predstavlja ulazni signal modificiran odgovarajućom funkcijom. Primjerice, izlaz neurona „ j “ opisan je dvjema jednadžbama:

$$U_j = \sum X_i \cdot w_{ij} \quad (1.1)$$

$$Y_j = F_{th}(U_j + t_j) \quad (1.2)$$

gdje su:

j - broj neurona

i - broj ulaza

X_i - vrijednost „ i ”-tog ulaza

w_{ij} - prije utvrđeni težinski koeficijent za ulaz „ i ”

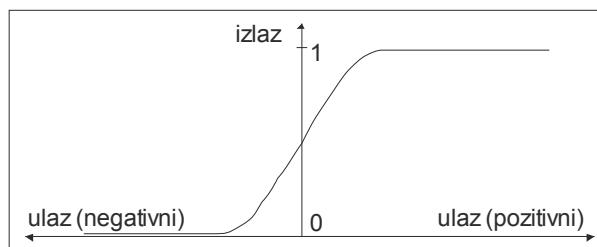
U_j - zajednička vrijednost izlaza svih ulaza neurona „ j ”

F_{th} - aktivacijska funkcija

Y_j - izlaz promatranog sloja ili ukupni izlaz mreže

Kada se izračuna zajednička vrijednost U_j , ona se uspoređuje s vrijednošću odbacivanja hipoteze (engl. *threshold value, cutoff*), tj. testira se pokretanje aktivacijske funkcije F_{th} . Ukratko, prvi izraz (1.1) predstavlja skup operacija u neuronu, a drugi (1.2) ispituje aktivira li se taj isti neuron.

Aktivacijska funkcija obično je sigmoidnoga oblika (**slika 1.4**). Izlaz Y_j ulaz je za sljedeći sloj ili izlaz neuronske mreže ako se radi o posljednjemu sloju. Osim sigmoidne funkcije mogu se upotrijebiti i drugi oblici aktivacijskih funkcija.



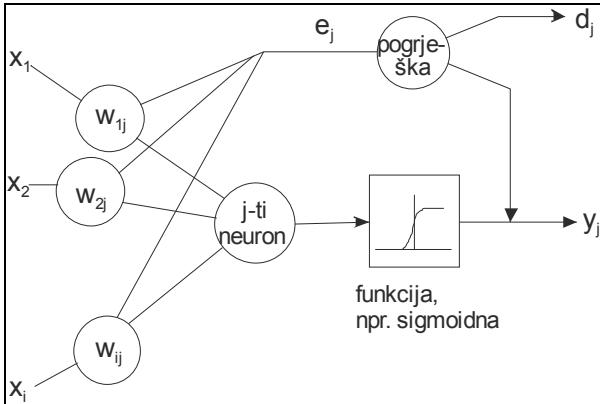
Slika 1.4: Sigmoidna aktivacijska funkcija

U jednadžbi (1.1) podrazumijeva se da postoji prethodno utvrđeni

težinski koeficijenti, definirana vrijednost odbacivanja hipoteze i određen broj slojeva i neurona u svakome od tih slojeva. Tek kada su utvrđeni ti elementi, moguće je dobiti odgovor neuronske mreže za neki skup ulaznih podataka. Prve dvije spomenute vrijednosti (težinski koeficijenti i vrijednost odbacivanja) mogu se mijenjati i prilagođavati u prvome razdoblju rada mreže, ili u vremenu dok mreža još „uči”.

1.4. UČENJE MREŽE

Da bi neuronska mreža zaista oponašala rad ljudskoga mozga, potrebno je unutar nje simulirati proces učenja. To se u sustavima neuronskih mreža naziva uvježbavanjem (engl. *training*). Uvježbavanje treba biti planirano tako da kasnija upotreba mreže daje odgovarajući izlaz. Ako se pritom može odrediti razlika između stvarnoga i željenoga odgovora mreže, dobije se iznos pogreške koji se može vratiti natrag u mrežu kako bi se ona bolje uvježbala (**slika 1.5**). Pogreška određena na svakome neuronu služi za prilagođavanje postojećih težinskih koeficijenata i vrijednosti njihove aktivacije.



Slika 1.5: Prilagođavanje težinskih koeficijenata i smanjivanje pogreške

Takva korektivna procedura nazvana je mrežom s postupkom povratne informacije (engl. *backpropagation network*). Ponavlja se toliko puta, dok se pojedinačna ili ukupna pogreška ne spusti ispod željene vrijednosti. Nakon toga je proces uvježbavanja neuronske mreže završen i ona se može upotrijebiti za obradbu novih ulaznih podataka.

Matematički izrazi koji opisuju učenje mreže obuhvaćaju nekoliko postupaka i pojmove kojima se oni određuju. Tako se postupak vraćanja informacije unutar mreže kreće unatrag počevši od izlaznoga sloja i definiran je sljedećim jednadžbama:

$$w_{ij} = w_{ij}^* + LR \cdot e_j \cdot X_i \quad (1.3)$$

$$e_j = Y_j \cdot (1 - Y_j) \cdot (d_j - Y_j) \quad (1.4)$$

gdje su:

i - broj ulaza j -toga neurona u izlaznom sloju

w_{ij} - broj neurona

w^*_{ij} - korekcija težine određena u postupku učenja

LR - iznos učenja (engl. Learning Rate)

e_j - iznos pogreške

X_i - vrijednost i -toga ulaza

Y_j - stvarni izlaz

d_j - željeni izlaz

Izraz (1.4) može se modificirati ovako (1.5):

$$e_j = Y_j \cdot (1 - Y_j) \cdot \sum (e_k \cdot w^*_{jk}) \quad (1.5)$$

gdje su:

e_j - iznos pogreške u promatranom neuronu „k”

w^*_{jk} - korekcija težina u promatranim parovima neurona „j” i „k”

U tome slučaju razlika između željenoga i stvarnoga izlaza zamijenjena je zbrojem pogrešaka na svakome neuronu „k” u sloju koji slijedi odmah nakon sloja koji se obrađuje, a ovisno o prethodno prilagođenim težinama. Iznos učenja (skr. „LR”) utječe na prethodno određene težinske koeficijente i računa nove. On također utječe na brzinu procesa učenja. Obično se počinje nižom vrijednošću, a ako je proces uvježbavanja spor, vrijednost se

povećava. Najčešće se prilagođavanje težinskih koeficijenata radi kroz nešto proširenu **jednadžbu (1.6)**:

$$w_{ij} = w^*_{ij} + (1 - M) \cdot LR \cdot e_j \cdot X_j + M \cdot (w^*_{ij} - w^{**}_{ij}) \quad (1.6)$$

gdje su:

M - momentni faktor

$w^*, **$ - težinski koeficijenti određeni u prethodna dva koraka

U tu jednadžbu uveden je momentni faktor 'M' te se upotrebljavaju težinski koeficijenti iz prethodnih dvaju koraka. Ako je 'M = 0' jednadžba se vraća na **izraz (1.3)**, koji je jednostavnija procjena težinskih koeficijenata. Većom vrijednošću 'M' pojačan je utjecaj prethodnih vrijednosti težina u njihovoј novoj procjeni. To u nekim slučajevima može poboljšati iznos učenja.

Jedan dio skupa ulaznih podataka najčešće se ostavlja po strani za provjeru (engl. *validation*) neuronske mreže, koja slijedi nakon uvježbavanja. Kod testnoga skupa podataka već je poznato kakvi se izlazi trebaju dobiti pa je tako moguće kontrolirati kvalitetu uvježbavanja.

Na kraju opisanoga postupka mreža je spremna obraditi skupove podataka kod kojih izlazna vrijednost nije poznata. Tada se više ne primjenjuje povratni postupak, tj. mreža više ne uči i ne proširuje svoje mogućnosti, već se računaju samo nove vrijednosti iz uspostavljenih odnosa. Svako novo proširivanje mogućnosti mreže

zahtijeva pripremu i analizu novoga skupa podataka za uvježbavanje.

1.5. MREŽA S POVRATNIM POSTUPKOM

U ranim danima razvoja umjetne inteligencije **Rosenblatt (1957, 1958)** je radeći u aeronautičkome laboratoriju „Cornell” razvio mehanizam zvan *perceptron*, koji se temelji na pohrani podataka onako kako se to odvija u ljudskome umu. Takav postupak imao je svojstva učenja. Osnova je te neuronske strukture, naravno, umjetni neuron, čija aktivacija ovisi o rezultatu obradbe aktivacijske funkcije. Vraćajući se ponovno na definiciju mreže preko ulaznih, skrivenih i izlaznoga sloja, naglašava se važnost *težinskih koeficijenata* (1.7):

$$U_j = (X_i \cdot w_{ij}) \quad (1.7)$$

gdje su (primjenjeno na pojedinačni neuron):

U_j - vrijednost izlaza neurona „ j ”

X_i - vrijednost ulaza „ i ”

w_{ij} - prethodno određeni težinski koeficijenti za ulaz „ i ” i neuron „ j ”

Težinski koeficijenti se primjenjuju u svakome skrivenom sloju upotrebom aktivacijske funkcije (1.8):

$$Y_j = F(U_j + t_j) \quad (1.8)$$

gdje su (primjenjeno na cijelu mrežu):

Y_j - izlaz sloja „ j “ (može biti i ukupni izlaz mreže)

F - aktivacijska funkcija

U_j - izlaz neurona „ j “

t_j - ciljna vrijednost za neuron „ j “

Jednadžba (1.7) podrazumijeva da su prethodno određeni težinski koeficijenti za svaki neuron, a **jednadžba (1.8)** da su određene i vrijednosti prihvaćanja hipoteze aktivacijskom funkcijom, broj slojeva te broj neurona u svakome sloju. Vrijednosti težinskih koeficijenata i prihvaćanja hipoteze mijenjaju se kroz razdoblje uvježbavanja mreže, tražeći najmanju ukupnu pogrešku mreže.

Kako je opisano, najjednostavnija arhitektura mreže temelji se samo na perceptronima. Njezino je ograničenje prepoznavanje veza u podatcima koje su predstavljene isključivo linearnim matricama. To ograničenje prevladano je uvođenjem nove paradigme ili algoritma (spomenutoga u potpoglavlju 1.4.) nazvanoga *povratnim postupkom* (engl. *back error propagation* ili skr. *backprop*). Time je unaprijeđena arhitektura pojedinačnoga perceptrona, ponajprije uvođenjem većega broja skrivenih slojeva (odakle potječe naziv *višeslojna mreža*; engl. *Multiple Layer Perceptron* ili skr. *MLP*), a

zatim i vraćanjem rezultata unatrag i ponavljanjem iteracija veliki broj puta.

Algoritam povratnoga postupka podrazumijeva da učenje mreže uključuje određivanje razlike između stvarnoga i želenoga odgovora, tj. izračun pogreške vraća se natrag u mrežu s ciljem postizanja najuspješnijega učenja. Takva pogreška izračunata je za svaki neuron te je upotrijebljena za prilagodbu težinskih koeficijenata i vrijednosti aktivacijske funkcije. Na temelju takva korektivnog postupka mreža je nazvana *mrežom s povratnim postupkom* tijekom učenja i provjere mreže. On se ponavlja toliko puta dok pojedinačna ili ukupna pogreška nije niža od postavljene granične vrijednosti. Nakon dosezanja te granice učenje mreže je završeno i ona može biti primjenjena za predviđanje na temelju novih podataka. Jednadžba algoritma povratnoga postupka prikazana je **izrazom 1.9:**

$$[w_i]_{novi} = [w_{i-1}]_{stari} + LR \cdot TF \cdot CT + MC \cdot \Delta w \quad (1.9)$$

gdje su:

$[w_i]_{novi}$ - težinski koeficijent ulaza u „i-toj“ iteraciji

$[w_{i-1}]_{stari}$ - težinski koeficijent ulaza u prethodnoj iteraciji

LR - iznos učenja (engl. Learning Rate) koji upućuje na razinu upotrebe aktivacijske funkcije i koeficijenta momenta (engl. Momentum Coefficient) u svakoj iteraciji. Ako je $LR = 0$, aktivacijska funkcija nije upotrijebljena, a rad cijele mreže temelji se isključivo na upotrebi koeficijenta momenta;

- TF* - aktivacijska funkcija, ovdje prevedena i kao prijenosna funkcija (engl. Transfer Function). Postoji nekoliko oblika takvih funkcija, a ovdje je upotrijebljena sigmoidna, tj.
- $$f(x) = \frac{1}{1+e^x};$$
- CT* - korekcijski izraz (engl. Correction Term). Vrijednost korekcijskoga izraza ovisi o razlici između stvarne (mjerene) i mrežom uvježbane vrijednosti;
- MC* - koeficijent momenta (engl. Momentum Coefficient) određuje koliki je utjecaj prethodne iteracije u trenutnoj kalkulaciji
- Δw - razlika spomenutih težinskih koeficijenata

Takav postupak danas je još uvijek najpopularnija temeljna paradigma koja se primjenjuje u neuronskim mrežama. Ipak, upotreba povratnoga postupka može znatno produžiti vrijeme uvježbavanja mreže pa postoji nekoliko metoda nadogradnje kojima se smanjuje taj problem, ali i poboljšavaju neki drugi elementi mreže. Na primjer, znatno smanjenje vremena učenja postupno je postignuto uvođenjem metode *postupnoga opadanja* (engl. *gradient descent*), kojom je poboljšan algoritam povratnoga postupka.

1.6. MREŽA S RADIJALNOM FUNKCIJOM

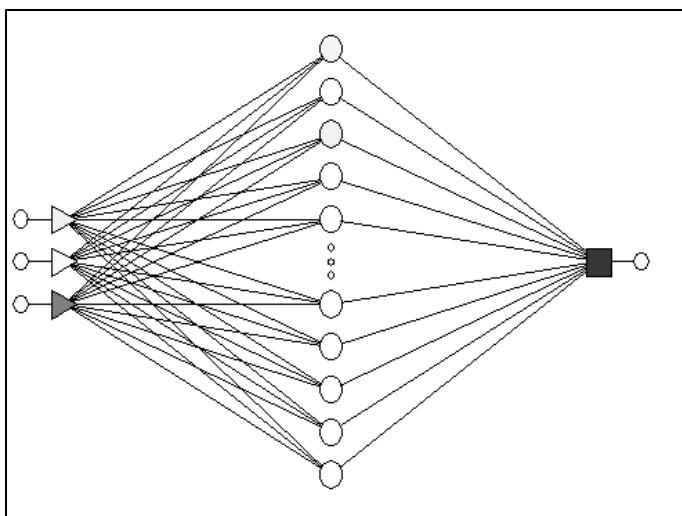
Mrežu s radijalnom funkcijom (engl. *Radial Basis Function*, skr. *RBF*) predložio je M. J. D. Powel (opisano u: **Karatalopoulos, 1996**). Može se upotrebljavati u istim situacijama kao i mreža s postupkom povratne informacije. Ta mreža upotrebljava radijalno simetričnu i radijalno ograničenu aktivacijsku funkciju u svojem skrivenom sloju. Mreža s radijalnom funkcijom nema neke nedostatke mreže s postupkom povratne informacije, kao što su problem lokalnoga minimuma i dugotrajan proces učenja, no zahtijeva više računanja u fazi prekida rada mreže prije negoli sama kroz zadani broj iteracija dosegne zadani minimum.

Mreža se sastoji samo od triju slojeva, tj. od ulaznoga, skrivenoga i izlaznoga sloja (**slika 1.6**). Takva arhitektura, uz veliki broj neurona u skrivenom sloju, karakteristika je RBF mreže. Broj neurona u ulaznome sloju odgovara broju ulaznih varijabli te, primjereno tomu, broj neurona u izlaznome sloju odgovara broju izlaznih varijabli.

Algoritam učenja u mreži s radijalnom funkcijom može se, kroz slojeve, opisati na sljedeći način:

1. Učenje počinje u skrivenome sloju s nenadgledanim algoritmom kako bi se odredilo središte.
2. Učenje se nastavlja u izlaznemu sloju s nadgledanim algoritmom kako bi se izračunala pogreška.

3. Istodobno se primjenjuje nadgledani algoritam u skrivenome i izlaznome sloju kako bi se prilagodile težine u mreži.

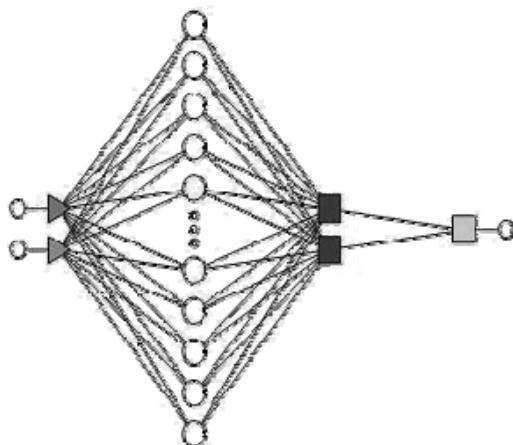


*Slika 1.6: Jednostavan prikaz mreže s radijalnom funkcijom s velikim brojem neurona u skrivenome sloju (izvor: **Statistica**, 2007)*

Iako mreža s radijalnom funkcijom ima brzi algoritam za učenje, ponekad se može dogoditi da je potrebno više vremena za učenje nego kod mreže s postupkom povratne informacije. Početna faza učenja kod mreže s radijalnom funkcijom temelji se na nenadgledanoj fazi pridodavanja podataka pojedinim skupinama te bi se stoga moglo dogoditi da se u toj fazi izgube neke važne informacije.

1.7. MREŽA S POSTUPKOM POOPĆENE REGRESIJE

Neuronska mreža s postupkom poopćene regresije (engl. *Generalized Regression Neural Network*, skr. *GRNN*) predstavlja unaprijeđenu verziju RBF mreže jer u svojoj građi obvezno sadržava dva skrivena sloja, uz uobičajeni ulazni i izlazni sloj. Broj je neurona u prvoj skrivenome sloju velik i ovisi o veličini ulaznoga skupa podataka, dok broj neurona u drugome skrivenom sloju mora biti dva (**slika 1.7**).



Slika 1.7: Jednostavan prikaz mreže s poopćenom regresijom s velikim brojem neurona u skrivenome sloju (Statistica, 2007)

Postupak obradbe informacija u ovoj neuronskoj mreži može se kroz slojeve opisati na sljedeći način:

1. Podatci proslijedeni iz ulaznoga sloja obrađuju se u prvoj skrivenom sloju. Prvi skriveni sloj mora sadržavati onoliko neurona koliko ima slučajeva koji se koriste u obradbi podataka. Ovdje se određuju težinski koeficijenti za pojedini neuron, uz definiranje koliko će okolnih slučajeva (neurona) imati utjecaj na vrijednost u promatranome neuronu.
2. Drugi skriveni sloj obvezno se sastoji od dvaju neurona. Jedan neuron predstavlja sumu (tzv. „neuron nazivnik”, engl. *denominator unit*) svih težinskih koeficijenata i primjenjivat će se kao nazivnik u jednadžbi konačnoga izračuna predviđene vrijednosti. Vrijednost izlaza drugoga neurona (tzv. „neuron brojnik”, engl. *numerator unit*) predstavlja sumu težinskih koeficijenata pomnoženih sa zadanim izlaznom vrijednosti.
3. U izlaznemu sloju predviđena se vrijednost izračunava kao kvocijent dviju izlaznih vrijednosti neurona iz drugoga skrivenoga sloja.

Mreža s postupkom poopćene regresije djelomično nasljeđuje svojstva od RBF mreže od koje je uspješnija u slučaju kada je manji ulazni skup podataka (sadržava veći broj neurona u skrivenom sloju uz drugačiji način izračuna vrijednosti). Zbog svojega načina izračunavanja vrijednosti mreža ima tendenciju „zaglađivanja“ rezultata ovisno o postavi težinskoga koeficijenta.

1.8. LITERATURA

1. Anderson, J. A. & Rosenfeld, E. (1989): Neurocomputing: Foundations of Research. Cambridge, MA: MIT Press.
2. Karatalopoulos, S. V. (1996): Understanding neural networks and fuzzy logic, basic concepts and application. IEEE Press.
3. McCormack, M. D. (1991): Neural Computing in Geophysics. The Leading Edge, 10/1, Society of Exploration Geophysicists.
4. Riedmiller, M. & Braun, H. (1993): A direct adaptive method for faster backpropagation learning: The RProp algorithm. Proc. of the IEEE Intl. Conf. on Neural Networks, San Francisco, 586–591.
5. Rosenblatt, F. (1957): The perceptron: A perceiving and recognizing automaton. Technical report 85-460-1, Project PARA, Cornell Aeronautical Lab.
6. Rosenblatt, F. (1958): The perceptron: A probabilistic model for information storage and organization in the brain. Psychological Review, 65, 386–408.

2. PREDVIĐANJE KLASTIČNIH FACIJESA NEURONSKOM MREŽOM, PRIMJER POLJA OKOLI

Primjer u ovome poglavlju predstavlja izvadak iz jednoga od prvih radova tiskanih u nas s tematikom primjene neuronskih mreža u analizi ležišta ugljikovodika (**Malvić, 2006**).

2.1. OSNOVNI GEOLOŠKI ODNOSI U POLJU OKOLI

Polje Okoli sadržava nekoliko pješčenjačkih ležišnih „serija”, od kojih se svaka dijeli na nekoliko pojedinačnih ležišta. No, pojam „serija” ovdje je napisan unutar navodnika kako bi se razlikovao od formalno definirane kronostratigrafske jedinice (veće od doba, a manje od sistema). Pisana pod navodnicima predstavlja neformalnu jedinicu koja obuhvaća nekoliko ležišta iz kojih se proizvode ugljikovodici.

Struktura Okoli predstavljena je brahiantiklinalom izduženom pravcem SZ–JI, u dubljim dijelovima rasjednutom. Ležišne su stijene gornjopontske („serije” „b” i „c”) te pliocenske („serije” „p”, „A”, „B”, „a”) starosti. Ukupno je otvoreno 11 ležišta unutar „serije” „c” (c₁–c₁₁). „Serija” „a” (ležišta a₁, a₂, a₃) iskorištava se za utiskivanje i skladištenje plina, dok se danas kao eksploracijski objekti za plin vode „serije” „b” i, poglavito, „serija” „c”. Pješčenjačka šupljikavost varira između 14 i 37 %, a propusnost

između 1,3 i $24,8 \times 10^{-3} \mu\text{m}^2$ (**Jüttner et al., 2001; Saftić et al., 2001**). Debljina pješčenjačkih ležišta varira približno između 1 metra i 20 metara.

Strukturni podaci preuzeti su iz baze tvrtke INA d. d. (**Atlas polja, 2005**) te su razlučeni intervali ležišta c₂. „Serija” „c” razvijena je u najvećemu dijelu strukture Okoli, a pojedinačna ležišta uglavnom su međusobno konkordantna, s lokalno korelativnim laporima u krovini i podini.

Ležište	Bušotina B-1 (aps. dubine u metrima)	Bušotina B-2 (aps. dubine u metrima)
c ₁	2088,5 – 2098,5	2123,0 – 2125,5
Lapor	2098,5 – 2108,5	2125,5 – 2135,0
c ₂	2108,5 – 2132,5	2135,0 – 2164,0
Lapor	2132,5 – 2147,5	2164,0 – nedostaje
c ₃	2147,5 – 2152,0	nedostaje – nedostaje
Lapor	2152,0 – 2159,5	nedostaje – 2184,0
c ₄	2159,5 – 2177,5	2184,0 – 2192,0

Tablica 2.1: Smještaj ležišta c₁ – c₄ u analiziranim bušotinama

U bušotini B-1 lapor u krovini i podini ležišta c₂ omedjen je ležištim c₁ i c₃ (normalan konkordantni slijed, **tablica 2.1**). U bušotini B-2 takve granice predstavljaju ležišta c₁ i c₄ (ležište c₃ je zalapreno, **tablica 2.1**). Bušotina B-1 smještena je približno na tjemenu, a B-2 na sjeverozapadnome krilu strukture.

Upotrijebljene karotažne krivulje za buštinu B-1 su GR (krivulja prirodne radioaktivnosti), R_{16} (krivulja otpornosti – „mala normala“) i R_{64} (krivulja otpornosti – „velika normala“). Ulazne krivulje u buštoni B-2 su GR, PORE (krivulja efektivne šupljikavosti), PORT (krivulja ukupne/totalne šupljikavosti), PORW (krivulja šupljikavosti u dijelu stijene zasićene 100 % vodom), R_{16} , SANDSTONE (krivulja udjela pješčenjaka) i SHALE (krivulja udjela laporanog).

Izlazna krivulja u obama slučajevima nazvana je „ležište“. Ta krivulja predstavlja „kategoriziranu“ varijablu, definiranu brojčano s 0 i 1. Broj 0 predstavlja lapor, a 1 pješčenjak. Te vrijednosti poredane su po dubini zahvaćenoga intervala te na taj način opisuju facijes odabranoga ležišta, krovinskoga i podinskoga laporanog. Cilj analize programom cVision je predviđanje točnoga poretku brojeva 0 i 1, tj. položaj laporanog i pješčenjaka, odnosno što točnija rekonstrukcija vrijednosti varijable nazvane „ležište“, kojom su predstavljeni facijesi.

Za polje Okoli napravljena su brojna geološka istraživanja. Facijesna analiza pokazala je homogenost i razlučivost koja se može opisati matematički (**Hernitz et al., 2001**) te su izračunati eksperimentalni semivariogrami šupljikavosti i propusnosti prema podatcima iz ležišta a₁. Interpretacija krivulja temeljila se na utvrđivanju semivariogramskih trendova u različitim klastičnim rezervoarima (**Kupfersberger & Deutsch, 1999**). Dokazano je kako su ležišta serije „a“ podijeljena u zone s obzirom na varijaciju petrofizikalnih podataka. Nadalje, nekoliko tih zona može se

povezati u veću cjelinu 2. reda, a tada se opaža i ciklični trend postupnoga porasta vrijednosti s dubinom. Variogramski doseg šupljikavosti u ležištu a₁ iznosi 3,2 – 5,3 metara i na toj udaljenosti postoji međusobna zavisnost uzoraka šupljikavosti. Kako je to ležište reprezentativno za cijelu seriju „a”, tim dosezima mogu se ekstrapolirati petrofizikalne vrijednosti u neuzorkovane dijelove serije „a”. Kod propusnosti doseg iznosi 2,2 metra. Autori su tako dokazali kako je petrofizikalne parametre, a time i facijese u polju Okoli, moguće opisati geomatematičkim alatima u koje se ubrajaju i neuronske mreže.

2.2. PROGRAM cVision

Za facijesnu analizu ležišta u polju Okoli upotrijebljen je cVision (pokusna licenca) proizvođača *Neuro Genetic Solution* (NGS) koji se bavi razvojem programa i analizom podataka iz ležišta ugljikovodika (**Fruhwirth, 2005**). Program je dodatak (engl. *AddIn*) unutar MsExcel™ okruženja, pa se podatci učitavaju iz jedne ili više tablica oblika „.xls”. Posebni dio programskoga algoritma nazvan je *lokalno prilagodiva pravila učenja* (engl. *local adaptive learning rules*). Time je korisniku omogućeno da pojmom *iznos učenja mreže* (engl. *learning rate*) poznaje samo elementarno. Uz to, svaka sinaptička veza između neurona u različitim slojevima ima svoju vlastitu vrijednost iznosa učenja, prilagođenu tijekom uvježbavanja.

Automatiziran je i proces određivanja veličine mreže, čime je onemogućeno zagušenje prilikom modeliranja, odnosno predimenzioniranje zbog memoriranja privremenih podataka ili

analiziranja nekarakterističnih, redundantnih podataka. Svi skriveni slojevi spojeni su prema naprijed kroz sve moguće kombinacije, čime je dobivena arhitektura *potpuno povezanih perceptron* (engl. *completely connected perceptrons*). Ulazni podatci podijeljeni su u skupine namijenjene učenju (engl. *Learning*, skr. L ; nekada se rabi kao istoznačnica i pojam uvježbavanje kao prijevod za *training*), provjeri (engl. *Validation*, skr. V) i predviđanju (engl. *Testing*, skr. T ; nekada se rabi kao istoznačnica i pojam predviđanje kao prijevod za *prediction*), otprilike u omjeru 80 %: 10 %: 10 %.

2.3. VRSTA UPOTRIJEBLJENE MREŽE I REZULTATI

Za analizu je odabrana vrsta mreže *potpuno povezanih perceptron*. Najbolja mreža odabrana je prema iznosu domene pogreške. Pogrješka procjene je određena prema kriteriju provjere uvježbanosti neuronskoga algoritma (engl. *validation error*). Određen je broj mrežnih modula u mreži (engl. *experts in cluster*) uz različite početne uvjete, a odabrana je vrijednost od 10 modula. Vrijednost prema kojoj se inicira prvi modul naziva se *slučajan broj* (engl. *random seed value*), a početno je postavljen na 0,01. Sljedeći modul inicira se s prethodnom vrijednošću uvećanom za 1 itd. Razvoj mreže podrazumijeva njezinu nadogradnju povećanjem broja skrivenih slojeva za 1 do maksimalne dopuštene vrijednosti.

2.3.1. Uvježbavanje mreže i njezini izlazi

Preko opcija opisanih u prethodnom poglavlju određuju se pravila te inicijalni iznos učenja. U analizi je odabранo lokalno prilagodivo pravilo nazvano unaprijeđeni RProp algoritam (**Riedmiller & Braun, 1993**), tj. IRprop+ (iz engl. *Improved Resilient propagation plus*). Kao početni iznos odabrana je vrijednost 0,01, koja se samostalno prilagođava tijekom učenja. U okvirima mreže definiraju se kriteriji prema kojima se zaustavlja njezin rad, tj. analiza.

Prvi je takav kriterij pogreška. Kada njezina vrijednost padne ispod graničnoga kriterija, analiza se prekida. Drugi je kriterij izražen najvećim brojem ciklusa uvježbavanja, nakon kojega se rad mreže zaustavlja bez obzira na prvi kriterij.

Rezultati analize facijesa u polju Okoli bili su predstavljeni tablicama i grafikonima, posebno izraženim za tri vrste izlaznih mreža nazvanih *najbolja mreža*, *trenutno najbolja mreža* i *niz karakterističnih mreža*. *Najbolja mreža* (engl. *face machine*) sadržava rezultate o najboljoj mreži tijekom uvježbavanja i oni su završno mjerilo uspješnosti mreže. *Trenutno najbolja mreža* (engl. *best machine*) sadržava podatke o trenutno najboljoj iteraciji. *Niz karakterističnih mreža* (engl. *trip machine*) ujedinjuje niz najboljih rezultata dobivenih tijekom uvježbavanja (tj. rezultate u prvim dvjema vrstama mreža).

2.3.2. Rezultati analize facijesa u polju Okoli (ležište „c₂“)

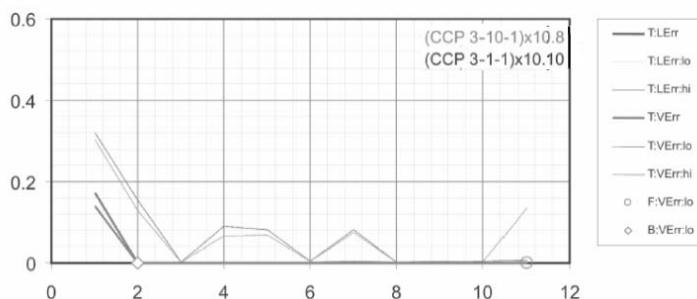
Rezultati su prvo prikazani odvojeno za bušotine B-1 i B-2, a zatim zajednički u zaključku. Iz bušotine B-1 upotrijebljene su krivulje GR, R₁₆ i R₆₄. Za učenje mreže (engl. *learning or L*) ukupno su upotrijebljena 153 podatka s vrijednošću 0 te 142 podatka s vrijednošću 1. Za provjeru (engl. *validation or V*) 48 podataka imalo je vrijednost 0, a 50 podataka vrijednost 1.

LEGENDA (za skupinu od po tri stupca): 1 – Tip podataka; 2 – Kategorička varijabla „ležište“; 3 – Vjerojatnost uspješnoga predviđanja								
L	0	78,3	V	1	78,3	L	0	78,3
L	0	78,3	L	1	78,3	V	0	82,1
L	0	78,3	L	1	78,3	L	0	78,3
L	0	78,3	L	1	78,3	L	0	78,3
V	0	82,1	L	1	78,3	L	0	78,3
L	0	78,3	L	1	78,3	V	0	82,1
V	0	82,1	L	1	78,3	V	0	82,1
L	0	78,3	L	1	78,3	L	0	78,3
L	0	78,3	L	1	78,3	L	0	78,3
V	1	82,1	L	1	78,3	L	0	78,3
L	1	78,3	L	1	78,3	L	0	78,3
L	1	78,3	L	1	78,3	V	0	82,1
V	1	82,1	L	0	78,3			
L	1	82,1	L	0	82,1			

Tablica 2.2: Vjerojatnosti uspješnosti učenja mreže za bušotinu B-1

Najbolja mreža obilježena je s ukupno 31 515 iteracija, s vremenom učenja od 5,40 minuta te s prosječnom pogreškom učenja 0,00173. U bušotini B-1 je obrađeno ukupno 393 podatka.

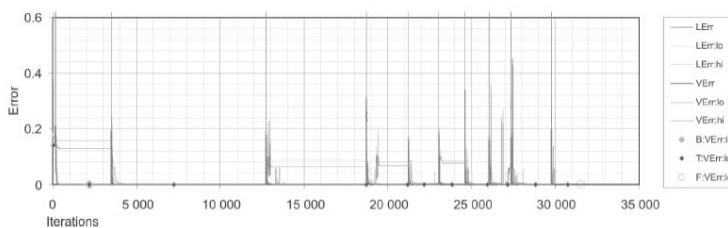
Očitani podatak, kategorička vrijednost te uspješnost učenja i provjere mreže iskazani su u **tablici 2.2** i na **slici 2.1**. Rezultat uspješnosti postupka nigdje nije bio manji od 78,3 % (oznaka L znači učenje, a V provjeru). Vrlo je zanimljivo tijekom uvježbavanja mreže u bušotini B-1 pratiti varijaciju pogreške te položaj ukupno i trenutno najbolje mreže u odnosu na 30 000 načinjenih iteracija (**slika 2.2**).



Slika 2.1: Odnos pogrešaka tijekom učenja (L), provjere (V) i predviđanja (T) mreže te položaj ukupno (B) i trenutno (F) mreže u bušotini B-1 (iz *Malvić, 2006*)

Istovrsno uvježbavanje i predviđanje napravljeno je u bušotini B-2. Ponovno bi u slučaju idealno uvježbane mreže stvarne vrijednosti trebale u potpunosti odgovarati kategoričkoj varijabli „ležište“. Rezultati predviđanja u procesima uvježbavanja i provjere prikazani su u **tablici 2.3**. Ipak, vjerojatnost ispravnoga uvježbavanja i predviđanja (0 ili 1) procijenjena je na preko 80 % za cijelo ležište. U toj bušotini upotrijebljen je nešto veći broj krivulja koje prikazuju prirodnu radioaktivnost (GR), posredno izračunate šupljikavosti efektivnu – PORE, ukupnu – PORT, te dijela prostora zasićenoga

vodom – PORW), zatim otpornost (R_{16} i R_{64}) te ponovno krivulje dobivene posredno, koje označavaju facijese (SANDSTONE i SHALE). Za učenje mreže (engl. L – Learning) ukupno je upotrijebljeno 225 podataka s vrijednošću 0 te 215 podataka s vrijednošću 1. Za provjeru (engl. V – Validation) 71 podatak imao je vrijednost 0, a 75 podataka vrijednost 1. Ukupno je to bilo 586 podataka, od kojih je svaki deseti prikazan u **tablici 2.3**.



Slika 2.2: Varijacije pogrješke tijekom iteracija te položaj trenutno (F) i ukupno (B) najbolje mreže u bušotini B-1 (iz Malvić, 2006)

Mreža je programirana na 28 599 iteracija, a dobivena je prosječna pogrješka učenja 0,002681. Slične su vrijednosti dobivene i za mrežu u bušotini B-1. Ipak, zbog većega broja upotrijebljenih krivulja ukupno je vrijeme uvježbavanja mreže bilo duže oko 3 puta te je iznosilo 16,13 minuta. Ipak, pregledom **tablice 2.3** vidljivo je kako predviđene i stvarne vrijednosti imaju znatno manji stupanj podudarnosti. Prema facijesima, predviđanje vrijednosti 1 (odnosno pješčenjačkoga facijesa) 100 % su podudarne. No, kod krovinskoga i podinskoga laporanja (0) te se vrijednosti znatno razlikuju te je tu u samo 7,8 % slučajeva ispravno predviđen lapor. Brojčano, od 296 ulaznih čelija opisanih kao lapor, vrijednost 0 ispravno je predviđena u 23, a zamijenjena brojem 1 u 273 slučaja.

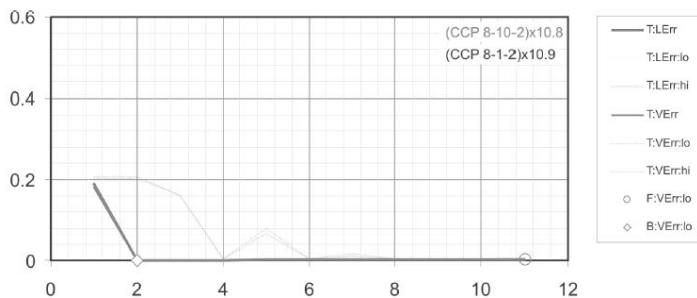
LEGENDA (za skupinu od po tri stupca): 1 – Tip podataka; 2 – Kategorička varijabla „ležište”; 3 – Vjerojatnost uspješnoga predviđanja

L	0	82,1	L	1	82,1	L	0	82,1
L	0	82,1	L	1	82,1	L	0	82,1
L	0	82,1	L	1	82,1	L	0	82,1
L	0	82,1	L	1	82,1	V	0	88,1
V	0	88,1	L	1	82,1	L	0	82,1
L	0	82,1	L	1	82,1	V	0	88,1
V	0	88,1	L	1	82,1	V	0	88,1
L	0	82,1	L	1	82,1	L	0	82,1
L	0	82,1	V	1	88,1	L	0	82,1
V	0	88,1	L	1	82,1	L	0	82,1
L	1	82,1	L	1	82,1	L	0	82,1
L	1	82,1	L	1	82,1	L	0	82,1
V	1	88,1	V	1	88,1	L	0	82,1
L	1	82,1	V	1	88,1	L	0	82,1
V	1	88,1	L	1	82,1	V	0	88,1
L	1	82,1	L	1	82,1	L	0	82,1
L	1	82,1	L	1	82,1	-	-	-
L	1	82,1	V	0	88,1	-	-	-
L	1	82,1	L	0	82,1	-	-	-
L	1	82,1	V	0	88,1	-	-	-

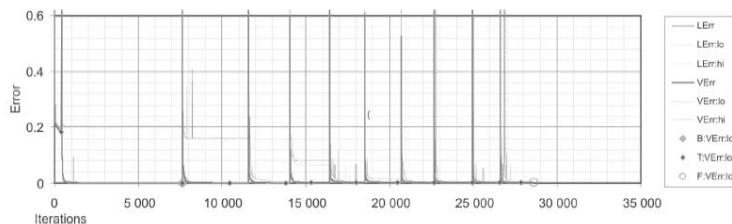
Tablica 2.3: Vjerojatnosti uspješnosti učenja mreže za buštinu B-2

Ista je pojava zabilježena i u buštoni B-1 (**tablica 2.2** i **slike 2.3** i **2.4**) pa se postavlja pitanje uzroka zamjene tako velikoga broja laporovitih intervala pješčenjakom. Odgovor je u vrsti i broju upotrijebljenih karotažnih krivulja. Od njih jedna prikazuje prirodnu radioaktivnost (GR), a druge dvije otpornosti (R_{16} i R_{64}). Razumno je pretpostaviti da bi analiza temeljena na krivuljama spontanoga potencijala, odnosno na krivuljama karotaže šupljikavosti (zvučna

karotaža, karotaža gustoće, neutronska karotaža), znatno olakšala razlikovanje lapora od pješčenjaka upotrebom neuronskoga algoritma.



Slika 2.3: Odnos pogrješaka tijekom učenja (L), provjere (V) i predviđanja (T) mreže te položaj ukupno (B) i trenutno (F) najbolje mreže u bušotini B-1 (iz Malvić, 2006)



Slika 2.4: Varijacija pogrješke tijekom iteracija te položaj trenutno (F) i ukupno (B) najbolje mreže u bušotini B-1 (iz Malvić, 2006)

2.4. ZAKLJUČAK O UPOTREBI NEURONSKIH MREŽA U PREDVIĐANJU FACIJESA

Prikazana analiza jedan je od prvih objavljenih pokušaja da se u

Hrvatskoj upotreboom neuronskih alata obrade mjerni podatci u naftnome ležištu. Stoga rezultate treba promatrati u obliku smjernica koje su pomogle u kasnijim, ponešto drugačijim, neuronskim analizama ležišta ugljikovodika (drugačijim i po vrsti mreže i po tipu ulaznih podataka). Ipak, postoji i dio konkretnih postignuća koja se odnose na upotrebu neuronskoga alata u predviđanju klastičnih facijesa u donjopontskim sedimentnim stijenama Savske depresije. Tako je opaženo sljedeće:

1. Postignuto je izvrsno podudaranje predviđenoga i stvarnoga položaja pješčenjačkih intervala unutar ležišta.
2. Nasuprot tomu, loše je podudaranje predviđenoga i stvarnoga položaja krovinskoga i podinskoga laporanog.
3. Programska vjerojatnost točnoga predviđanja facijesa, odnosno litološkoga sastava, vrlo je velika u bušotini B-1 (na temelju 3 karotažne krivulje), gdje iznosi minimalno 78,3 %, a u bušotini B-2 (na temelju 7 karotažnih krivulja) minimalno je 82,1 %.
4. Položaj *najbolje mreže* javlja se u relativno ranoj fazi rada mreže. Za buštinu B-1 takva mreža zabilježena je u 2186. iteraciji, a za buštinu B-2 u 7626. iteraciji. To pokazuje kako u analizi facijesa, kod izmjene pješčenjaka i laporanog, nije potreban toliki broj iteracija (oko 30 000) za uvježbavanje mreže, već da se znatno veći dobitak postiže povećanjem broja karakterističnih karotažnih krivulja.
5. Prema tome, mreža u polju Okoli preuvježbana je te ne sadržava dovoljno podataka za prepoznavanje laporovitih intervala.
6. U eventualnim dalnjim sličnim facijesnim analizama bilo bi dobro ulazne podatke proširiti dodatnim karotažnim krivuljama

koje dobro karakteriziraju litologiju, šupljikavost i zasićenje, poput krivulja spontanoga potencijala (engl. *Spontaneous Potential*, skr. *SP*), kompenzirane karotaže neutrona (engl. *Compensated Neutron log*, skr. *CN*), karotaže gustoće (engl. *DENSity log*, skr. *DEN*) te zvučne karotaže (engl. *ACoustic log*, skr. *AC*, upotrebljava se i engleski izraz *Sonic* bez kratice).

7. Tada bi *najbolja mreža* vjerojatno bila konfigurirana s vjerojatnošću ispravnoga predviđanja većom od 90 %.

2.5. LITERATURA

1. Atlas proizvodnih plinskih polja u Republici Hrvatskoj – verzija 7.2. (2005): Fond struč. dok., INA-Industrija nafte, SD Istraživanje i proizvodnja nafte i plina, Sektor za razradu, 243 str.
2. Hernitz, Z., Bokor, N. & Malvić, T. (2001): Geostatistical Modeling of Petrophysical Data of Oil Fields in the Northern Croatia. Proceedings, 63rd EAGE Conference & Technical Exhibition, P611, Amsterdam.
3. Jüttner, I., Saftić, B. & Velić, J. (2001): Distribution of Porosity and Permeability within the Pontian Sandstones in the Western Part of Sava Depression in Relation to their Stratigraphic Architecture and Palaeotectonic Relations. Nafta, Special Issue Dedicated to 2nd International Symposium on Petroleum Geology, April 22–24, 1999, Eds. Hernitz, Z. & Sečen, J., Sept. 2001, 139–144, Zagreb.
4. Kupfersberger, H. & Deutsch, C. V. (1999): Methodology for Integrating Analog Geologic Data in 3D Variogram Modeling. AAPG Bulletin, 83, 8, 1262–1278, Tulsa.
5. Malvić, T. (2006): Clastic facies prediction using neural network (case study from Okoli field) [Predviđanje klastičnih facijesa neuronskom mrežom (primjer polja Okoli)]. Nafta, 57, 10, 415–431.
6. Riedmiller, M. & Braun, H. (1993): A direct adaptive method for faster backpropagation learning: The RProp algorithm. Proc. of the IEEE Intl. Conf. on Neural Networks, San Francisco,

- 586–591.
7. Saftić, B., Peh, Z., Velić, J. & Jüttner, I. (2001): Interdependence of Petrophysical Properties and Depth: Some Implications of Multivariate Solution on Distinction Between the Lower Pontian Hydrocarbon-bearing Sandstone Units in the Western Part of the Sava Depression. *Geol. Croatica*, 54, 2, 259–277, Zagreb.
 8. Fruhwirth, R. K. (2005): cVision Users Guide Version-2. Neuro Genetic Solutions GmbH, Centre for Applied Technology, 31 str., Leoben.

3. PREDVIĐANJE LITOLOŠKOGA SASTAVA I INTERVALA ZASIĆENIH UGLJIKOVODICIMA, PRIMJER POLJA KLOŠTAR

Sadržaj ovoga poglavlja većinom je objavljen u radu **Cvetković et al. (2009)**.

3.1. OSNOVNI GEOLOŠKI ODNOSI U POLJU KLOŠTAR

Regionalno-geološki, polje Kloštar nalazi se na prostoru Savske depresije unutar Panonskoga bazena. Ležišta ugljikovodika otkrivena su u litostratigrafskim jedinicama miocena te u stijenama podine miocena. Prema **Brod (1945)** slojevitoga su i masivnoga tipa. Dosad je otkriveno ukupno 20 ležišta koja su svrstana u 5 neformalnih litostratigrafskih jedinica:

- I. pješčenjačka „serija”
- II. pješčenjačka „serija”
- „prevalencijenezijske naslage”
- „miocen”
- „temeljno gorje”.

Prosječna je šupljikavost pješčenjačkih ležišta 25 %, a prosječna efektivna debljina iznosi 5 metara. Propusnost rezervoarskih stijena kreće se u rasponu od 2,4 do $179,9 \times 10^{-3} \mu\text{m}^2$. Proizvodnja je 2005. godine bila $79,6 \text{ m}^3/\text{dan}$, odnosno oko $29\,000 \text{ m}^3/\text{god}$. Gustoća nafte je 843 kg/m^3 . Do danas je na polju izrađeno ukupno 196 bušotina, od kojih su 64 mjerne, 59 proizvodnih, 68 je tehnički likvidirano, a

5 se iskorištava za utiskivanje slojne vode (izvor podataka: **Atlas polja, 2005**).

3.2. ANALIZE NEURONSKIM MREŽAMA U POLJU KLOŠTAR

U ovome poglavlju prikazat će se način i rezultati predviđanja neuronском mrežom. Sve analize i dijagrami napravljeni su u programskome paketu StatSoft STATISTICA 7.0. Istraživanje je načinjeno uvježbavanjem neuronske mreže na određenome dubinskome intervalu bušotine (nadgledano učenje) te je tako uvježbana neuronska mreža korištena u svrhu predviđanja vrijednosti željenih parametara u njoj dosad, nepoznatim intervalima. Kao ulazne vrijednosti koristit će se elektrokarotažni podaci bušotina Klo-44 i Klo-71.

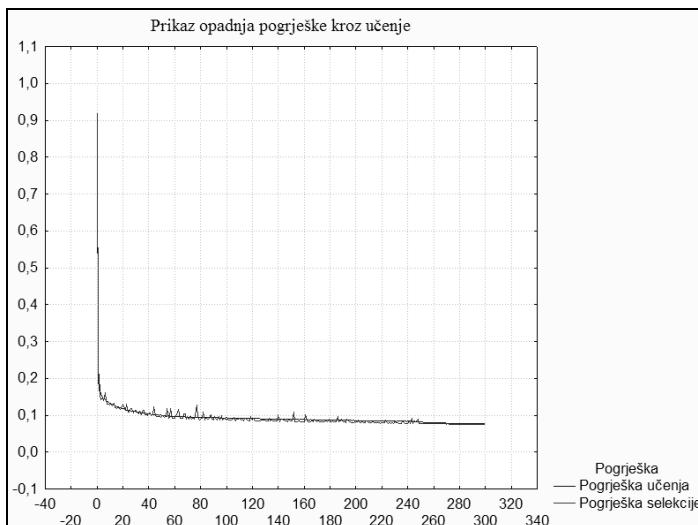
Rezultati upotrebe neuronskih mreža bit će prikazani pomoću dijagraama i tablica. Dijagrami se sastoje od linije koja predstavlja stvarne (zadane vrijednosti) i linije predviđenih vrijednosti označenih različitim bojama koje su naznačene u legendi. Predviđene vrijednosti u nazivlju imaju dodatak SNN (engl. *Statistica Neural Networks*).

3.2.1. Predviđanje litološkoga sastava

Za predviđanje litološkoga sastava ručno su izdvojeni slojevi pješčenjaka i lapora na karotažnim dijagramima bušotine Klo-44. Kao ulazni podatak za uvježbavanje neuronske mreže koristit će se vrijednosti spontanoga potencijala (SP) i otpornosti (R_{16} i R_{64}) te litološki sastav. Litološki sastav definiran je varijablom čija je vrijednost predviđena. Interval koji će se koristiti za uvježbavanje približno će odgovarati intervalu I. pješčenjačke „serije“ uključujući nekoliko metara iznad i ispod toga intervala kako bi se analizom obuhvatila određena debljina nepropusnih naslaga. Koristit će se neuronska mreža s radikalnom funkcijom i mreža s postupkom povratne informacije s nekoliko skrivenih slojeva odnosno MLP mreža. Predviđanje će se provoditi za interval koji približno odgovara II. pješčanoj „seriji“.

Ulagani skup za uvježbavanje u programu STATISTICA 7.0 automatski se dijeli tako da se jedna polovina skupa koristi za uvježbavanje, a druga polovina za određivanje uspješnosti mreže koja je izražena iznosom pogreške selekcije i pogreške uvježbavanja. Pogrješka selekcije predstavlja pogrešku u predviđanju na skupu izdvojenome za provjeru uspješnosti mreže, a pogreška uvježbavanja onu utvrđenu na skupu za uvježbavanje mreže. Prilikom uvježbavanja neuronske mreže program automatski zaustavlja uvježbavanje kada se dostigne unaprijed zadani iznos pogreške. Ako to nije postignuto, program se vraća na iteraciju u kojoj je postignuta najniža pogreška selekcije (**slika 3.1**).

Uspješnost uvježbavanja i predviđanja RBF i MLP neuronske mreže prikazana je u **tablici 3.1** i **slikama 3.2, 3.3, 3.4 i 3.5**.



Slika 3.1: Na ordinati su dane vrijednosti pogreške. Vrijednosti na apscisi predstavljaju broj iteracija.

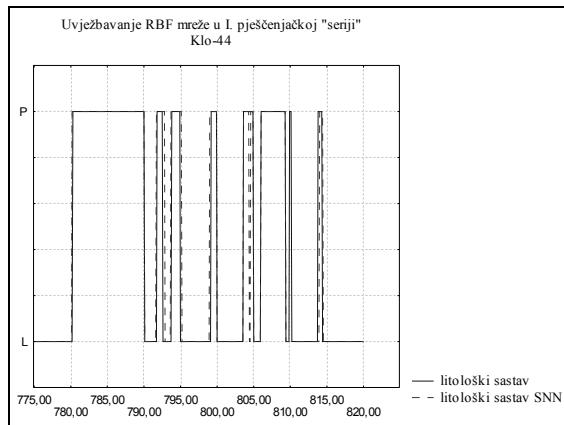
Tip neuronske mreže i svojstva ^a	Pogrješka uvježbavanja ^b	Pogrješka selekcije ^b
RBF 3:3-31-1:1	0,152942	0,172753
MLP 3:3-4-6-3-1:1	0,314380	0,1333478

Tablica 3.1: Prikaz parametara uvježbanih neuronskih mreža u bušotini Klo-44 za predviđanje litološkoga sastava (iz **Cvetković et al., 2009**)

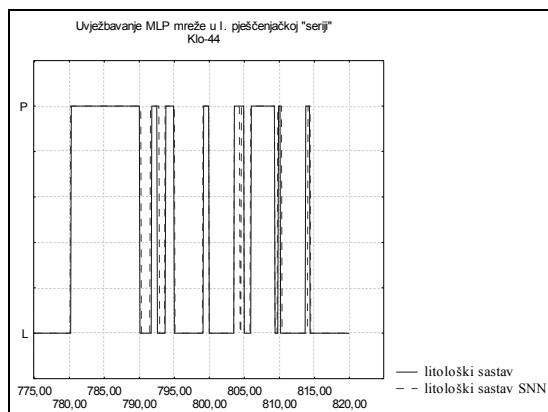
^a Svojstva neuronske mreže prikazana su tako da broj vrijednosti predstavlja broj slojeva u neuronskoj mreži. Prva i zadnja vrijednost predstavljaju broj neurona u ulaznom i izlaznom sloju, dok ostale vrijednosti prikazuju broj neurona u skrivenim slojevima.

^b Iznos pogreške prikazan je tako da 0 predstavlja 0 % pogreške, tj. 100 % uspješnosti, a iznos pogreške od 1 predstavlja 100 % pogreške, odnosno 0 %

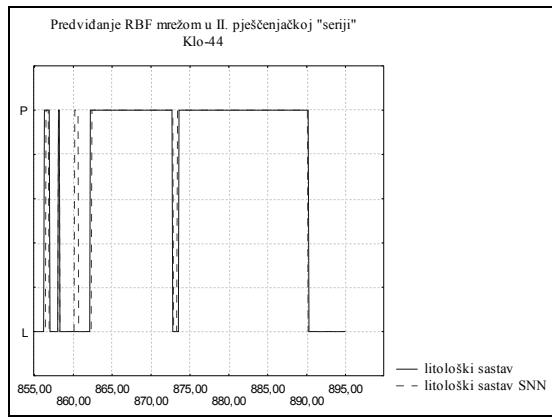
uspješnosti.



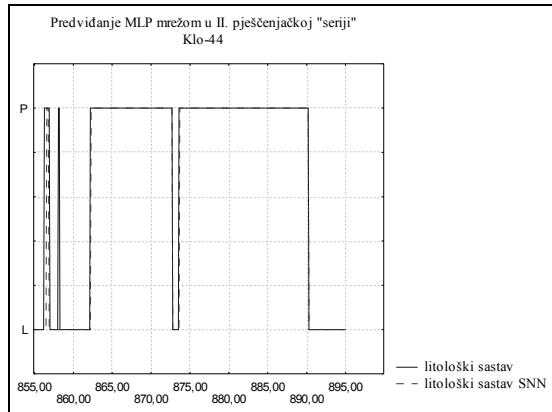
Slika 3.2: Na ordinati su dane vrijednosti litologije P – pješčenjak, L – lapor. Vrijednosti na apscisi predstavljaju dubinu naslaga u metrima (iz Cvetković et al., 2009).



Slika 3.3: Na ordinati su dane vrijednosti litologije P – pješčenjak, L – lapor. Vrijednosti na apscisi predstavljaju dubinu naslaga u metrima (iz Cvetković et al., 2009).



Slika 3.4: Na ordinati su dane vrijednosti litologije P – pješčenjak, L – lapor. Vrijednosti na apscisi predstavljaju dubinu naslaga u metrima (iz Cvetković et al., 2009).



Slika 3.5: Na ordinati su dane vrijednosti litologije P – pješčenjak, L – lapor. Vrijednosti na apscisi predstavljaju dubinu naslaga u metrima (iz Cvetković et al., 2009).

Prema **slikama 3.2** i **3.3** može se vidjeti da su obje mreže uspješno uvježbane u intervalu I. pješčenjačke „serije”, iako bi se po vrijednostima pogreške kod MLP mreže moglo očekivati da će rezultati biti loši, što dokazuje da je pogreška selekcije vrlo važan parametar u krajnjoj učinkovitosti neuronske mreže. Na **slikama 3.4** i **3.5** dani su rezultati predviđanja litološkoga sastava u intervalu II. pješčenjačke „serije”. Obje mreže dale su vrlo dobre rezultate. Male pogreške prisutne su u predviđanju intervala iznad II. pješčenjačke „serije”. Iako obje mreže pokazuju približne rezultate, može se zaključiti da MLP mreža daje bolje rezultate kod predviđanja nego RBF mreža.

3.2.2. Predviđanje zona zasićenih ugljikovodicima

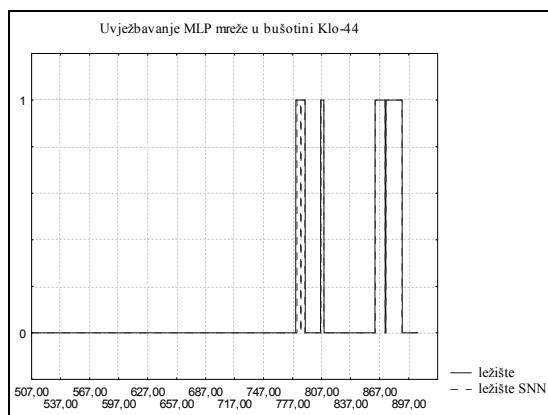
Za razliku od predviđanja litološkoga sastava, neuronska mreža uvježbavana je na jednoj bušotini, a predviđanje je obavljeno na drugoj bušotini. Zone zasićene ugljikovodicima određene su prema otklonu krivulje R_{64} kao varijabla ležišta s vrijednostima 0 i 1 (0 predstavlja nezasićeni, a 1 zasićeni dio). Takve kategoričke vrijednosti (0 i 1) korištene su za uvježbavanje i provjeru uspješnosti neuronske mreže. Osim vrijednosti zasićenja korištene su krivulje SP-a, R_{16} , R_{64} , dubine (m) i atributivna varijabla litološkoga sastava. Za predviđanje varijabli ležišta korištena je MLP mreža sa šest neurona u prvome te osam neurona u drugome skrivenome sloju. Uspješnost uvježbavanja i predviđanja varijabli ležišta dana je u **tablici 3.2** te na **slikama 3.6** i **3.7**.

Tip neuronske mreže i svojstva ^a	Pogrješka uvježbavanja ^b	Pogrješka selekcije ^b
MLP 5:5-6-8-1:1	0,056897	0,091173

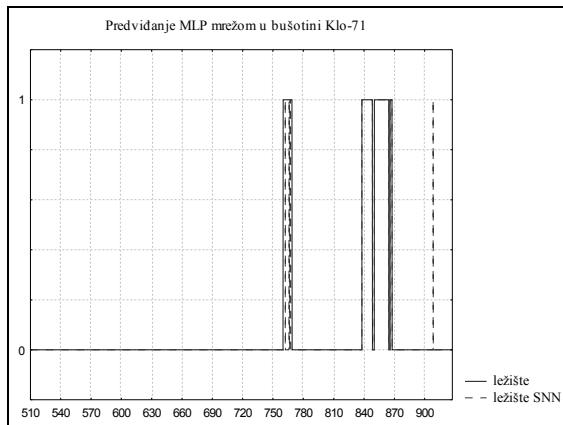
Tablica 3.2: Prikaz parametara uvježbane neuronske mreže u bušotini Klo-44 u svrhu predviđanja varijabli ležišta (preuzeto iz Cvetković et al., 2009)

^a Svojstva neuronske mreže prikazana su tako da broj vrijednosti predstavlja broj slojeva u neuronskoj mreži. Prva i zadnja vrijednost predstavljaju broj neurona u ulaznome i izlaznomo sloju, dok ostale vrijednosti prikazuju broj neurona u skrivenim slojevima.

^b Iznos pogreške prikazan je tako da 0 predstavlja 0 % pogreške, tj. 100 % uspješnosti, a iznos pogreške od 1 predstavlja 100 % pogreške, odnosno 0 % uspješnosti.



Slika 3.6: Na ordinati su dane vrijednosti varijable ležište: 0 – nezasićeni dio, 1 – zasićeni dio. Vrijednosti na apscisi predstavljaju dubinu naslaga u metrima (preuzeto iz Cvetković et al., 2009).



Slika 3.7: Na ordinati su dane vrijednosti varijabli ležišta: 0 – nezasićeni dio, 1 – zasićeni dio. Vrijednosti na apscisi predstavljaju dubinu naslaga u metrima (preuzeto iz Cvetković et al., 2009).

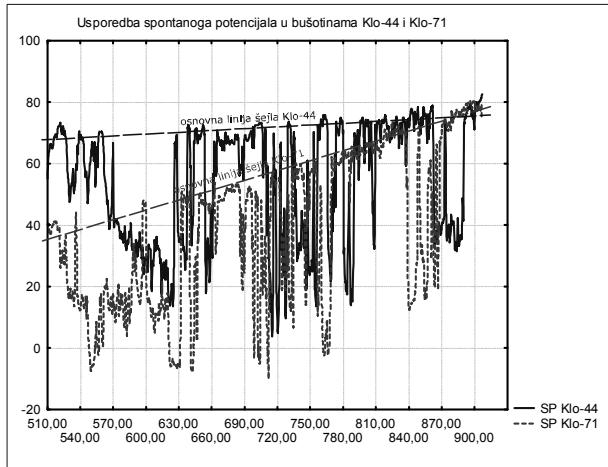
Na **slici 3.6**, gdje je prikazana uspješnost uvježbavanja neuronske mreže, može se vidjeti da je neuronska mreža točno predvidjela varijablu ležišta u intervalima I. i II. pješčenjačke „serije“. Uspješnost predviđanja ugljikovodicima zasićenih zona u bušotini Klo-71 prikazana je **slikom 3.7**. Neuronska je mreža s velikom točnošću odredila granice II. pješčenjačke „serije“, dok su granice I. pješčenjačke „serije“ također određene, no uz nešto manju točnost.

3.3. MOGUĆI PROBLEMI PRILIKOM ANALIZA NEURONSKIM MREŽAMA ZAPAŽENI U PRIMJERU POLJA KLOŠTAR

Općenito, za analize neuronskim mrežama vrijedi: što je veći broj ulaznih varijabli i broj slučajeva rezultati će biti pouzdaniji i mreža će uspješnije učiti, uz bolje predviđanje. Predviđanje litološkoga

sastava pokazalo se uspješnim, no samo ukoliko je skup podataka za uvježbavanje i predviđanje dolazio iz intervala unutar iste bušotine, tj. tu se govori o jednodimenzionalnoj ekstrapolaciji. Ukoliko bi se umjesto krivulja SP-a upotrijebile krivulje GR-a (prirodne radioaktivnosti), promjera bušotine, kompenzirane gustoće neutrona (CN), karotaže gustoće (DEN) i drugih koje karakteriziraju litološki sastav i zasićenje ugljikovodicima, dobili bi se bolji rezultati.

Problem koji se javlja kod uvježbavanja neuronske mreže za predviđanje litološkoga sastava jest pomak osnovne linije nepropusnih stijena koji je vidljiv kod krivulje SP-a u bušotini Klo-71, dok kod bušotine Klo-44 pomak nije izražen (**slika 3.8**). Uz uvrštavanje dubine kao varijable, kod uvježbavanja neuronske mreže nisu postignuti zadovoljavajući rezultati zbog toga što se osnovna linija nepropusnih stijena ne ponaša jednakom u objema bušotinama. Kod analize neuronskom mrežom za predviđanje zasićenja ugljikovodicima kao važan parametar koristila se varijabla kojom je opisan litološki sastav. Ona je bila definirana na temelju odvajanja intervala pješčenjaka od intervala laporanog prema položaju točaka infleksije na krivulji SP-a. Kada se atributivna varijabla ne bi koristila kao ulazna vrijednost u analizi neuronskom mrežom, uz vrijednosti karotažnih krivulja SP-a, R16 i R64, mreža ne bi pokazala zadovoljavajuću vrijednost predviđanja zbog nemogućnosti preciznoga definiranja relacije da varijabla ležišta ima pozitivnu vrijednost samo u pješčenjačkim slojevima. Varijabla ležišta vjerojatno se ne bi morala uvoditi kao ulazna vrijednost ako bi se koristile vrijednosti krivulja GR-a, promjera bušotina i druge.



Slika 3.8: Na ordinati su dane vrijednosti spontanoga potencijala u mV. Vrijednosti na apscisi predstavljaju dubinu naslaga u metrima.

3.4. ZAKLJUČAK O UPOTREBI NEURONSKIH MREŽA U PREDVIĐANJU LITOLOŠKOGA SASTAVA I ZASIĆENJA UGLJIKOVODICIMA

Prikazano je nekoliko neuronskih mreža koje su imale zadatak odrediti litološki sastav sedimenata gornjega panona (II. pješčenjačka „serija“) i donjega ponta (I. pješčenjačka „serija“) te zasićenost ugljikovodicima u njima. Uspješnost uvježbavanja i predviđanja neuronskim mrežama prikazane su grafički i tablično. Pješčenjački facijesi, gornjopanonske i donjopontske starosti, predstavljaju najprikladniji tip sedimenta za neuronske i statističke obradbe te su na analizirani takvim alatima. Na osnovi rezultata neuronskih analiza može se zaključiti:

- prilikom određivanja litološkoga sastava u bušotini Klo-44 pomoću neuronske mreže s radikalnom funkcijom i višeslojnom mrežom dobiveno je izvrsno poklapanje predviđenoga i stavnoga litološkoga sastava,
- određivanje zasićenosti ugljikovodicima u bušotini Klo-71 pomoću višeslojne mreže, uvježbane na bušotini Klo-44, daje izvrsno poklapanje između predviđenih i stvarnih vrijednosti.

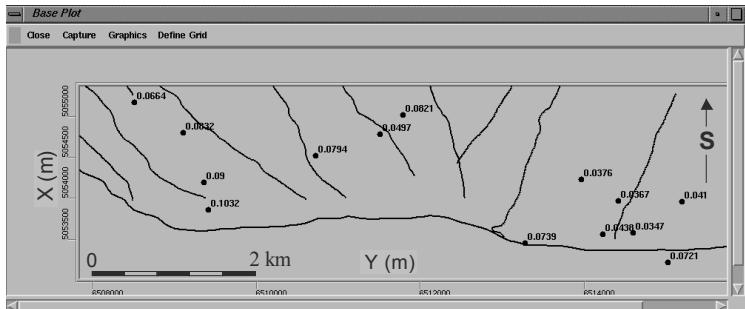
3.5. LITERATURA

1. Atlas proizvodnih plinskih polja u Republici Hrvatskoj – verzija 7.2. (2005): Fond struč. dok., INA-Industrija nafte, SD Istraživanje i proizvodnja nafte i plina, Sektor za razradu, 243 str.
2. Brod, I. O. (1945): Geological terminology in classification of oil and gas accumulation. AAPG Bulletin, 29, 12, 1738–1755.
3. Cvetković, M., Velić, J., Malvić, T. (2009): Application of neural networks in petroleum reservoir lithology and saturation prediction. Geologia Croatica, 62/2, 115–121.

4. PROCJENA ŠUPLJIKAVOSTI NEURONSKOM MREŽOM, PRIMJER POLJA BENIČANCI

U ovome poglavlju prikazano je istraživanje objavljeno izvorno u radu **Malvić & Prskalo (2007)** te prilagođeno obliku ove knjige. Naglasak je stavljen na vrstu upotrijebljene mreže te vrijednosti ulaznih podataka i njihovih linearnih veza koje su omogućile predviđanje šupljikavosti unutar cijelog ležišta nafte polja Beničanci neuronskim algoritmom.

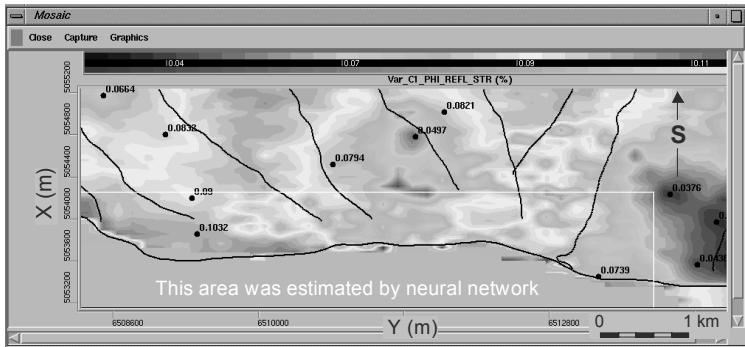
Naftno polje Beničanci smješteno je u istočnome dijelu Dravske depresije i svrstava se među pet najvećih ležišta ugljikovodika u Hrvatskoj. Zato primjena novijih analitičkih alata u izradbi geološkoga modela postaje vrlo smislenim zadatkom. Unutar ležišta badenske starosti bili su dostupni reinterpretirani bušotinski podaci na 14 lokacija (**slika 4.1**) te seizmički atributi interpretirani iz rezultata snimanja 3D seizmike (amplituda, faza i frekvencija). Modelirana je razdioba šupljikavosti kao najvažnije ležišne varijable (radi procjene ukupnoga volumena ležišta). Kao suvremena metoda procjene šupljikavosti ležišta upotrijebljena je neuronska mreža s povratnim postupkom (engl. *back propagation network*), čije je učenje načinjeno kroz 10 000 iteracija. Unutar mreže postavljena je linearna veza između svih triju seizmičkih atributa i šupljikavosti te je tražena najviša vrijednost njihove korelacije, odnosno minimalni iznos konvergencije uvježbavanja.



Slika 4.1: Indeksna karta šupljikavosti (iz Malvić & Prskalo, 2007)

Najbolja procjena šupljikavosti neuronskom mrežom postignuta je u slučaju kada su istodobno upotrijebljena sva tri seizmička atributa, što je potvrdilo pretpostavku da neuronske mreže obično postižu uspješnija predviđanja s većim brojem ulaza.

Rezultati dobiveni neuronskom mrežom za provjeru su uspoređeni s prethodno načinjenim geostatističkim kartama šupljikavosti (upotrebom kriginga i kokriginga). U tome slučaju najbolja interpolacija postignuta je kokrigingom upotrebom samo jednoga seizmičkoga atributa (snage refleksije kao izvedenice amplitude), koji je predstavljao sekundarnu varijablu (Malvić & Đureković, 2003). Relativno postupni prijelaz na karti šupljikavosti dobivenoj neuronskom mrežom te vrijednosti čelija koje rijetko dosežu minimum i maksimum ulaznoga skupa pokazali su da je neuronska procjena preciznija od onih na kartama dobivenim drugim interpolacijskim metodama.



Slika 4.2: Karta šupljikavosti dobivena kokrigingom u naftnom ležištu polja Beničanci (iz Malvić & Prskalo, 2007)

4.1. OSNOVNI GEOLOŠKI ODNOSI U POLJU BENIČANCI

Ležište naftnoga polja Beničanci masivnoga je tipa (klasifikacija iz **Brod, 1945; Brod & Jeremenko, 1957; Velić, 2007**), odnosno zamka je strukturno-stratigrafska (**Levorsen, 1956; Velić, 2007**). Sastavljen je uglavnom od dolomitnih i vapnenačkih breča badenske starosti. Tjeme je antiklinale na dubini od 1699 metara, prosječna šupljikavost ležišta iznosi 7,33 %, početno zasićenje vodom 28,1 %, a gustoća 875 kg/m^3 . Proizvodnja je započela 1972. godine, a danas se crpljenje odvija iz nešto više od 20-ak bušotina od njih ukupno 106. Posebna reinterpretacija karotažnih dijagrama načinjena je početkom ovoga stoljeća u 14 bušotina, tako da su one najnoviji i najpouzdaniji skup podataka za izradbu različitih modela ležišta. Također, otprilike u isto vrijeme snimljena je i 3D seizmika na području Beničanaca pružajući mogućnost interpretacije većega broja seizmičkih atributa. Ukupne geološke rezerve nafte u polju Beničanci iznose $34 \times 10^6 \text{ m}^3$ uz predviđeni iscrpk 52,5 %. U plićim,

miocenskim slojevima nalazi se nekoliko plinskih ležišta u pješčenjacima, gdje ukupne geološke rezerve iznose 2700×10^6 m³ uz iscrpk od oko 58 %. Iako je proizvodnja na polju u opadanju i dostiže najveći predviđeni iscrpk, povijest eksploracije pokazuje da su pridobive rezerve vjerojatno veće od predviđenih pa su i nove karakterizacije ležišta svakako isplative s obzirom na nisku cijenu rada računala u odnosu na količine ostvarene mogućim, čak i jednopostotnim povećanjem iscrpka.

4.2. ULAZNE VARIJABLE ZA NEURONSKU MREŽU

Kako je spomenuto, neuronska mreža primjenjena je na skupu od dvije korelativne vrste podataka. Primarni skup sadržavao je šupljikavost, a sekundarni tri seizmička atributa interpretirana iz 3D seizmičke kocke. Ti seizmički atributi bili su amplituda, frekvencija i faza, koje su kao odvojene varijable osrednjene u intervalu ležišta u 14 bušotina, gdje su iz najnovijih karotažnih mjerena interpretirane srednje šupljikavosti.

Tako su na polju Beničanci razvrstana dva ulazna skupa podataka – šupljikavost izračunata iz karotaže (14 točkastih vrijednosti) te seizmički atributi interpretirani iz seizmičke kocke (16 384 točkastih vrijednosti po atributu).

4.3. VRSTA I PARAMETRI UVJEŽBAVANJA NEURONSKE MREŽE

Za analizu je odabrana arhitektura mreže s povratnim postupkom (engl. *back propagation network*), u kojoj je tražena iteracija s najmanjom pogrješkom uvježbavanja. Uvježbavanje se sastojalo od utvrđivanja linearne zavisnosti vrijednosti šupljikavosti i seizmičkih atributa na istim lokacijama. S tako utvrđenom zakonitošću predvidene su šupljikavosti i na onim mjestima gdje su izmjerene samo vrijednosti seizmičkih atributa. Na mjestima gdje su postojali šupljikavost i seizmička snimanja, tražena je veza u svim mogućim slučajevima njihova kombiniranja, tj. korelacija šupljikavosti i jednoga atributa (tri mogućnosti), korelacija šupljikavosti i dvaju atributa (tri mogućnosti) te korelacija šupljikavosti i triju atributa (jedna mogućnost). Signali su transformirani upotrebom sigmoidne aktivacijske funkcije.

4.3.1. Vrijednosti robusnih parametara mreže

Pod izrazom „robustni parametar“ podrazumijeva se mrežna varijabla čija se manja promjena vrijednosti ne će odmah odraziti u radikalno drugačijemu rezultatu uvježbavanja. Mreža je u početku sadržavala 5 skrivenih slojeva, a taj je broj povećavan do 25. Tu je bila dobro izražena robustnost, jer povećanje broja slojeva nije znatnije uvećalo korelaciju šupljikavosti i atributa (za vrijednost 10^{-3} do 10^{-2}), dok je brzina uvježbavanja bila znatno manja.

Nadalje, iznos učenja (engl. *learning rate*) na kraju je postavljen na vrijednosti 0,9, a koeficijent momenta (engl. *Momentum Coefficient*) na 0,6. Povremeno su te vrijednosti varirane za vrijednost 0,1 u intervalu [0, 1], no nije bilo znatnijih promjena u pogrješci mreže. Broj iteracija variran je između 10 000 i 30 000, no kako nije bilo većih promjena u rezultatu, konačno je namješten na 10 000 kako bi se smanjilo vrijeme uvježbavanja.

4.3.2. Vrijednosti osjetljivih parametara mreže

Pod „osjetljivim“ parametrom podrazumijeva se onaj dio mreže gdje i mala promjena vrijednosti vodi do bitne promjene rezultata mreže, čime je kod takva parametra nužan i veći oprez prilikom odabira njegove vrijednosti.

Prvi takav parametar bio je broj istodobno promatranih atributa kod uvježbavanja. Pri tome je upotreba dvaju ili triju seizmičkih atributa zahtijevala da se prvo fizikalno objasni njihova povezanost. Iako sva tri atributa (frekvencija, faza i amplituda) izvor imaju u promjenama zvučnoga vala do kojih dolazi zbog njegove refleksije od različitih litoloških granica u podzemlju, njihova je veza često vrlo nejasna. Ipak, veće korelacije izračunate su uključivanjem većega broja atributa

Odabrana je log-sigmoidna aktivacijska funkcija te određena vrijednost konvergencijskoga kriterija ($\Sigma \epsilon^2$). Ako je iznos toga kriterija postao manji od granične vrijednosti, rad mreže prekinut je prije dosezanja korisnički postavljenoga broja iteracija. U

prikazanome modelu konvergencijski kriterij iznosio je 1, te je u jednom uvježbavanju mreža zaustavljena zbog te vrijednosti (a ne dostizanja najvećega broja iteracija).

4.4. REZULTATI NEURONSKE MREŽE

Kvaliteta uvježbavanja mreže izražena je kroz vrijednost korelacije između šupljikavosti i atributa, dok je *kriterij konvergencije* razmatran kao minimum pogreške postignut neuronskom mrežom. S obzirom na različit broj ulaza u mrežu, postignuti su sljedeći rezultati usporedbom različitih broja atributa:

Tri atributa korelirana s šupljikavošću:

- Amplituda + frekvencija + faza i šupljikavost – $R^2 = 0,987$; $\Sigma \varepsilon^2 = 0,329$.

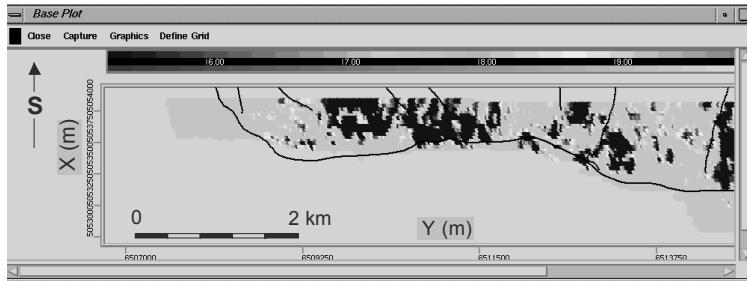
Dva atributa korelirana s šupljikavošću:

- Amplituda + frekvencija i šupljikavost – $R^2 = 0,496$; $\Sigma \varepsilon^2 = 1,935$.
- Amplituda + faza i šupljikavost – $R^2 = 0,603$; $\Sigma \varepsilon^2 = 1,740$.
- Faza + frekvencija i šupljikavost – $R^2 = 0,820$; $\Sigma \varepsilon^2 = 1,090$.

Jedan atribut koreliran s šupljikavošću:

- Amplituda i šupljikavost – $R^2 = 0,250$ i $\Sigma \varepsilon^2 = 2,730$.
- Frekvencija i faza, samostalno uspoređene s šupljikavošću, imale su vrlo male koeficijente determinacije.

Vidljivo je kako je najbolja korelacija ulaznih podataka te uvježbavanje neuronske mreže postignuto upotrebom svih triju atributa. Oni su korelirani s šupljikavošću koja se izvorno kretala u rasponu $5,3 - 11,1\%$, dok je predviđanje neuronском mrežom dalo vrijednosti koje su unutar toga intervala, ali čak u užim granicama (**slika 4.3**). Upotreba samo jednoga atributa dovela je do precjenjivanja predviđene šupljikavosti. Nadalje, zajedničko promatranje amplitude i frekvencije rezultiralo je procjenom većine vrijednosti šupljikavosti blizu gornje granice ranije spomenutoga intervala. Ako ponovno promatramo slučaj jednoga atributa, primjerice amplitude, kao onoga što se najbolje „očuva” na putu do površine te može najjasnije opisati stjenski sastav kroz koji je signal prošao, stupanj postignute korelacije za par amplituda – šupljikavost bio je samo 0,25, odnosno mreža je slabo uvježbana ($S_e^2 = 2,73$). Fizikalno, niže amplitude odgovarale su nižim šupljikavostima, no nije očuvan relativni odnos između tih varijabli. Na primjer, amplitudi od 1200 odgovara šupljikavost od $5,27\%$, a zatim $1472 = 7,3\%$, $1669 = 8,15\%$, $1990 = 8,17\%$, $2107 = 8,16\%$. Vidljivo je kako promjena nije linearna, tj. pravilo izvedeno iz nje naglašava procjenu šupljikavosti općenito bliže donjoj granici (tj. vrijednosti od $5,3\%$).



Slika 4.3: Karta šupljikavosti dobivena neuronskom mrežom u naftnome ležištu na južnom dijelu polja Beničanci (iz Malvić & Prskalo, 2007)

4.5. ZAKLJUČAK O UPOTREBI NEURONSKIH MREŽA U PREDVIĐANJU ŠUPLJIKAVOSTI

Dokazano je kako seizmički atributi mogu predstavljati dodatni vrijedan ulaz koji se može upotrijebiti u predviđanju šupljikavosti. Kvaliteta prikazane mreže s povratnim postupkom može se procijeniti iz vrijednosti dvaju parametara. Jedan je *koeficijent determinacije* (R^2), koji je računat za parove seizmički atribut(i) i šupljikavost. Drugi izlazni parametar jest *kriterij konvergencije*, tj. *postignuti minimum* ($\Sigma \varepsilon^2$). Najuspješnije uvježbana mreža imala je najveći koeficijent determinacije ($R^2 = 0,99$) te najmanji postignuti minimum ($\Sigma \varepsilon^2 = 0,329$). Te vrijednosti mogu se u svakoj iteraciji promijeniti za nekoliko postotaka, odražavajući tako stohastički element (tj. interval nesigurnosti koji pripada procjeni) u radu neuronskih veza i aktivacijskih funkcija.

Najbolje uvježbavanje postignuto je istodobnom upotrebot svih

triju dostupnih atributa, iako se u praksi interpretacije ležišta kvantitativnom metodom najčešće upotrebljava isključivo amplituda za procjenu šupljikavosti i, općenito, litološkoga sastava ležišta. Razlog je u samoj dubini ležišta te prilično heterogenom klastičnom sadržaju, čija je posljedica osciliranje kvalitete reflektiranoga signala (uz dodatnu okolnost da je teško dobro kalibrirati geofone na malim udaljenostima) te će se amplituda zaista bitno mijenjati u vremenu i prostoru. Nasuprot tomu, promjene kod frekvencije i faze signala znatno su manje. Uz to, u plićim, miocenskim pješčenjacima iznad naftnoga ležišta, nalaze se tanja ležišta zasićena plinom (s oko 30 % ukupnih količina plina dokazanih u polju). Taj fluid prigušuje izvorni seizmički signal reflektiran iz dubljih slojeva, a ponekad čak potpuno prikrije izvornu amplitudu karakterističnu za naftno ležište. Naravno, rezultat je velika varijacija u amplitudi iz istoga stratigrafskoga horizonta, a to je razlog zašto uvođenjem drugih dvaju atributa ipak dobivamo zbirni atribut koji je bolje kvalitete (s manjim varijacijama vrijednosti) negoli sama amplituda.

Upotrijebljena neuronska mreža pomogla je u određivanju šupljikavosti u ležištu nafte obilježenome priličnom heterogenošću, a time i nesigurnostima u predviđanju šupljikavosti bilo kojom metodom. Nadalje, zbog iznimno velikoga broja podataka i mogućnosti obradbe programom predviđanje je načinjeno na južnome dijelu polja. Neke promjene šupljikavosti mogu se uočiti i bez detaljnoga kartiranja, tj. poznavanjem samo točkastih, mjerenih vrijednosti te vrste taložnoga okoliša koji je postojao u vrijeme nastanka ležišnih stijena. Prvi podatci bili su poznati kao ulaz u neuronsku mrežu. Radi se o aluvijalnoj lepezi koja se pružala

smjerom (od svoga proksimalnoga do distalnoga dijela) od zapada na istok, ali i obrončanim brečama istaloženim u prostoru strukture Beničanci (**Tišljar, 1993**). Sličan aluvijalni taložni model opisan je i na drugim poljima kod nas koja imaju slične litofacijese (npr. **Malvić, 2006**). U tome je smjeru, zbog promjene veličine čestica (granulometrije), dolazilo i do postupnoga smanjivanja šupljikavosti, što je dodatni pristrani parametar na koji neuronska mreža nije mogla biti uvježbana.

4.6. LITERATURA

1. Brod, I. O. (1945): Geological terminology in classification of oil and gas accumulation. AAPG Bulletin, 29, 12, 1738–1755.
2. Brod, I. O. & Jeremenko, N. A. (1957): Osnovi geologii nafte i gase. Izdanie tretie, Gostoptehizdat, Moskva.
3. Levorsen, A. I. (1956): Geology of petroleum. Freeman, 703 str., San Francisco.
4. Malvić, T. (2006): Middle Miocene Depositional Model in the Drava Depression Described by Geostatistical Porosity and Thickness Maps (Case study: Stari Gradac-Barcs Nyugat Field). Rudarsko-geološko-naftni zbornik, 18, 63–70.

5. Malvić, T. & Đureković, M. (2003): Application of methods: Inverse distance weighting, ordinary kriging and collocated cokriging in porosity evaluation, and comparison of results on the Beničanci and Stari Gradac fields in Croatia. *Nafta*, 54, 9, 331–340.
6. Malvić, T. & Prskalo, S. (2007): Some benefits of the neural approach in porosity prediction (Case study from Beničanci field) [Koristi upotrebe neuronske mreže u procjeni poroznosti (na primjeru polja Beničanci)]. *Nafta*, 58, 9, 455–467.
7. Tišljar, J. (1993): Sedimentary bodies and depositional models for the Miocene oil-producing areas Ladislavci, Beničanci and Obod (Croatia). *Nafta*, 44, 10, 531-542.
8. Velić, J. (2007): Geologija ležišta nafte i plina. Sveučilište u Zagrebu, Rudarsko-geološko-naftni fakultet, 342 str., Zagreb.

5. REKONSTRUKCIJA DIJELOVA KAROTAŽNIH KRIVULJA POMOĆU NEURONSKIH MREŽA, PRIMJER IZ HRVATSKOGA DIJELA PANONSKOGA BAZENSKOGA SUSTAVA

U ovome poglavlju prikazani su rezultati rekonstrukcija intervala karotažnih krivulja pomoću neuronskih mreža. Slična analiza prikazana je na XIII. mađarskome geomatematičkom i II. hrvatsko-mađarskome geomatematičkom kongresu (**Cvetković & Bošnjak, 2009**). Analize su napravljene na osnovi podataka o ležištima iz polja Kloštar, Stari Gradac-Barcs Nyugat i Đeletovci kako bi se prikazala uspješnost neuronskih mreža u rekonstrukciji karotažnih vrijednosti u stijenama različitoga litološkoga sastava.

Princip rada programa StatSoft STATISTICA 7.0 prikazan je u poglavlju 3. ove knjige kao i opća geološka obilježja polja Kloštar. Analize neuronskim mrežama prikazana je posebno za svako polje. Rezultati uspješnosti analiza su prikazani tablično, dijagramima razlika vrijednosti (engl. *Residual plot*) i troosnim dijagramima.

Pojedine analize ograničene su samo na jednu buštinu (1D ekstrapolacija). Unutar jedne bušotine odabran je kontinuirani interval relativno homogenoga sastava kako se ne bi dogodilo da je uvježbavanje i predviđanje neuronske mreže otežano zbog lošega odabira ulaznih podataka. U analizama su korištene krivulje zvučne karotaže (engl. *ACoustic log*, skr. *AC*), neutronske karotaže (engl. *Compensated Neutron log*, skr. *CN*), karotaže gustoće (engl.

DENsity log, skr. *DEN*) i karotaže prirodne radioaktivnosti (engl. *Gamma Ray log*, skr. *GR*). Za prikaz rezultata odabrane su tri najuspješnije neuronske mreže, i to jedna od svake vrste (MLP, RBF i GRNN).

5.1. OSNOVNI GEOLOŠKI ODNOSI U POLJU ĐELETOVCI

Polje Đeletovci smješteno je približno 20 kilometara jugoistočno od Vinkovaca te pripada Slavonsko-srijemskoj depresiji. Uz Đeletovce, koje je najveće, u toj depresiji nalaze se još samo tri polja – Tovarnik, Ilača i Privlaka. Polje je otkriveno 1982. godine bušotinom Đe-1, a proizvodnja je započela 1984. godine. Sva tri polja nalaze se unutar izdignute strukture „Vinkovci” koja se proteže od Vinkovaca na sjeverozapadu do Tovarnika na jugoistoku. Oblik strukture uvjetovan je oblikom paleozojskoga paleoreljefa, koje se neformalno naziva i „temeljno gorje”.

Ležišne stijene pretežno su paleozojske starosti, a predstavljeni su raspucanim i trošnim granitima, gnajsevima, dijabazima i različitim škriljavcima. Mlađi dio iznad erozijsko-transgresivne granice predstavljen je badenskim brečama i pješčenjacima. Zamke su strukturno-stratigrafskoga tipa (prema **Levorsen, 1957**), tj. ležište je masivnoga tipa (prema **Brod, 1945** te **Brod & Jeremenko, 1957**). Načinjeno je ukupno 60 bušotina, od kojih je 35 proizvodnih, 11 mjernih, 4 utisne za otpadne vode, a deset ih je tehnički likvidirano (**Atlas polja, 2005**).

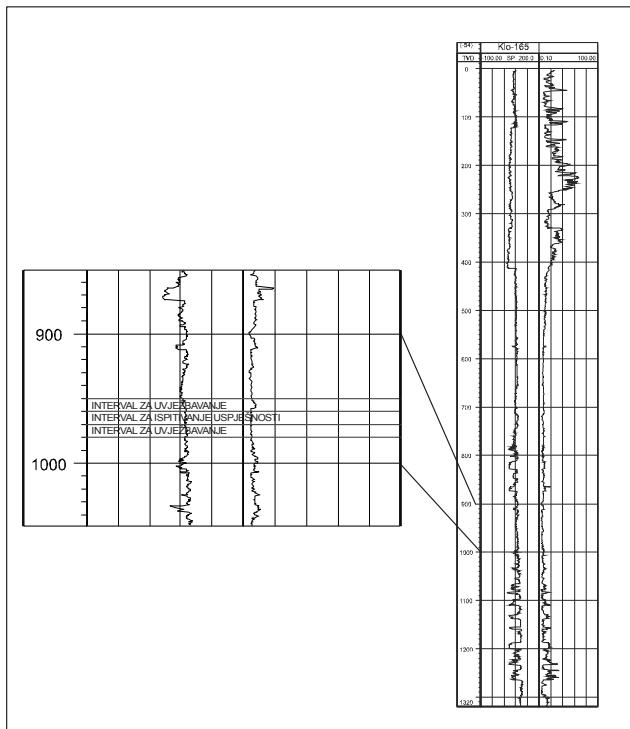
5.2. OSNOVNI GEOLOŠKI ODNOSSI U POLJU STARI GRADAC-BARCS NYUGAT

Stari Gradac-Barcs Nyugat jest plinsko-kondenzatno polje. Struktura se prostire s obiju strana hrvatsko-mađarske granice. Bušotina Bny-1 pokazala je 1979. godine mogućnost postojanja ležišta ugljikovodika, a polje je otkriveno buštinom StG-1 1980. godine. Do 2003. godine izrađeno je 16 bušotina, od toga 7 na hrvatskoj (StG-1, 1Z, 2, 3, 4, 5, 6) i 9 na mađarskoj (Bny-1, 2, 3, 4, 5, 6, 7, 8, 9) strani. Administrativno hrvatski dio polja nalazi se na područjima četiriju općina (Pitomača, Špišić Bukovica, Kloštar Podravski i Lukač), u Virovitičko-podravskoj i Koprivničko-križevačkoj županiji. U regionalnome geološkome pogledu struktura Stari Gradac-Barcs Nyugat pripada sjeverozapadnom dijelu Dravske depresije, tj. području dubokoga dijela Dravske depresije (s obzirom na ukupnu debljinu neogensko-kwartarnih sedimenata). Struktura čini jedinstvenu zonu s drugim dvjema bliskim strukturama – Molvama i Kalinovcem. Sve tri brahiantiklinale povezane su pravcем pružanja Z/SZ–I/JI, a u istome smjeru raste i njihova dubina (Molve – Kalinovac – Stari Gradac). Polje Stari Gradac ima strukturno-stratigrafski tip zamke (**Levorsen, 1956**), odnosno predstavlja masivno ležište ograničeno nepropusnim stijenama (**Brod, 1945 te Brod & Jeremenko, 1957**). Definirane su četiri proizvodna litofacijesa: *miocenski klastiti, klastiti srednjega trijasa, donjotrijaski kvarciti i dolomitti te permski metavulkaniti.*

5.3. REKONSTRUKCIJA KRIVULJA NEURONSKOM MREŽOM U POLJU KLOŠTAR

Za analizu je odabrana bušotina Klo-165 s dostupnim krivuljama karotaže zvuka (AC), neutronske šupljikavosti (CN) i gustoće (DEN). Odabrani interval od –950 do –980 metara približno odgovara I. pješčenjačkoj „seriji“ (**slika 5.1**). Prvih i zadnjih deset metara (od –950 do –960 m i od –970 do –980 m) intervala koristilo se za uvježbavanje neuronskih mreža, dok se interval od –960 do –970 metara koristio za ispitivanje uspješnosti uvježbane neutronske mreže.

Prema tome, neuronska mreža uvježbana je na 200 slučajeva, a ispitivanje uspješnosti na 100 slučajeva. Ulazne varijable bile su vrijednosti karotažnih krivulja AC-a i DEN-a pomoću kojih je predviđena vrijednost karotažne krivulje CN-a.



Slika 5.1: Prikaz bušotine Klo-165 s naznačenim dijelovima korištenim za analizu neuronskim mrežama

5.3.1. Rezultati analiza višeslojne neuronske mreže

Najuspješnija mreža sadržavala je dva skrivena sloja s po devet i šest neurona. (**tablica 5.1**).

Tip neuronske mreže i svojstva ^a	Pogrješka uvježbavanja ^b	Pogrješka selekcije ^b
MLP 2-9-6-1	0,187415	0,175165

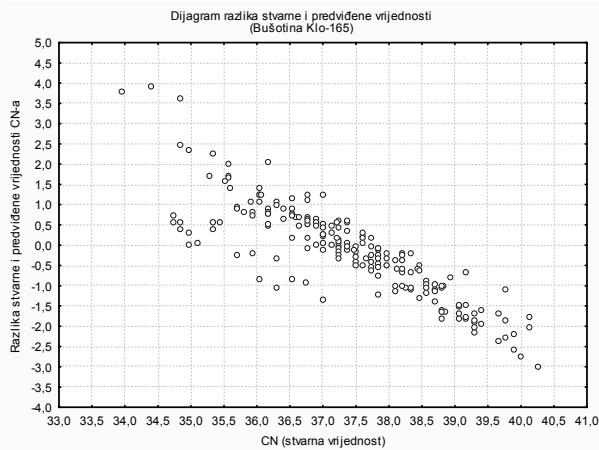
Tablica 5.1: Prikaz svojstava uvježbane mreže za predviđanje vrijednosti karotažne krivulje CN-a

^a Svojstva neuronske mreže prikazana su tako da broj vrijednosti predstavlja broj slojeva u neuronskoj mreži. Prva i zadnja vrijednost predstavljaju broj neurona u ulaznome i izlaznome sloju, dok ostale vrijednosti prikazuju broj neurona u skrivenim slojevima.

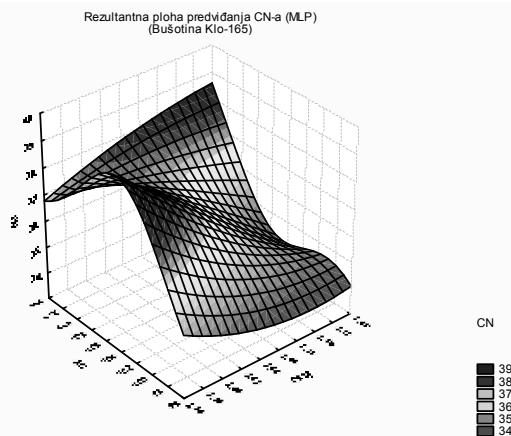
^b Iznos pogreške prikazan je tako da 0 predstavlja 0 % pogreške, tj. 100 % uspješnosti, a iznos pogreške od 1 predstavlja 100 % pogreške, odnosno 0 % uspješnosti.

Uspješnost MLP neuronske mreže za predviđanje vrijednosti iz intervala od –960 do –970 metara prikazana je na dijagramu razlika vrijednosti (**slika 5.2**), troosnomo dijagramu (**slika 5.3**) i na zbirnome prikazu karotažne krivulje s usporedbama uspješnosti predviđanja istoga intervala za sve korištene neuronske mreže (**slika 5.4**).

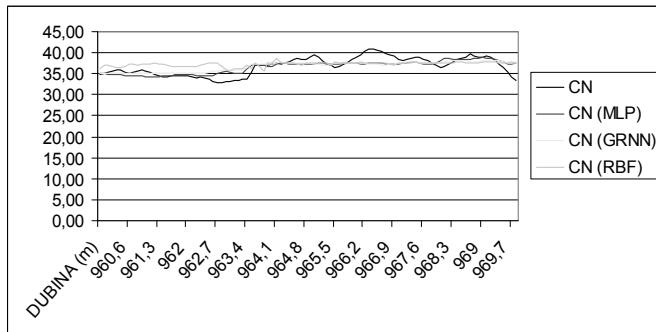
Vrijednosti za koje je najuspješnije predviđanje višeslojnom mrežom bile su iz intervala od 35,5 do 38,5 %, dok su vrijednosti s većim odstupanjima imale i veću pogrešku (**slika 4.3**). Na troosnomo dijagramu prikazana je rezultantna ploha iz koje se može vidjeti da neuronska mreža ima mogućnost predviđanja maksimalnih, minimalnih i srednjih vrijednosti CN-a (**slika 5.3**).



Slika 5.2: Prikaz razlike vrijednosti predviđene MLP mrežom (na ordinati) za pojedinu stvarnu vrijednost (prikazanu na apscisi)



Slika 5.3: Prikaz rezultantne plohe vrijednosti karotaže CN-a za MLP mrežu



Slika 5.4: Odnos vrijednosti CN-a predviđenih raznim neuronskim mrežama i stvarnih za interval od –960 do –970 m (buš. Kloš-165)

5.3.2. Rezultati analiza neuronske mreže s radikalnom funkcijom

Parametri najuspješnije RBF mreže prikazani su u **tablici 5.2.**

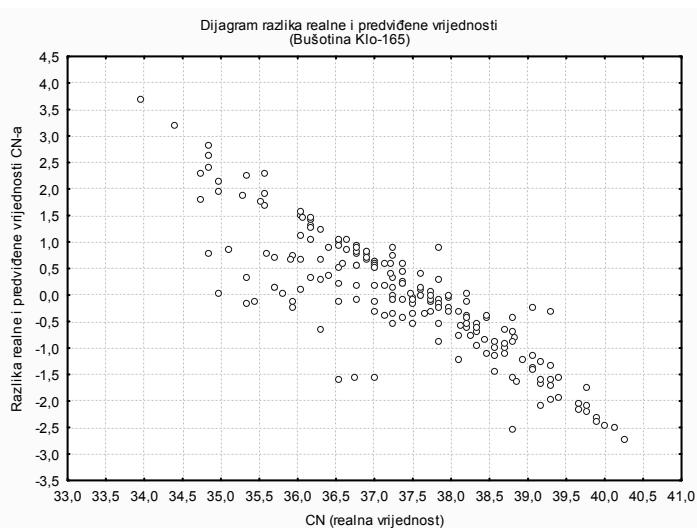
Tip neuronske mreže i svojstva ^a	Pogrješka uvježbavanja ^b	Pogrješka selekcije ^b
RBF 2-18-1	0,291071	0,299214

Tablica 5.2: Prikaz svojstava uvježbane mreže za predviđanje vrijednosti šupljikavosti iz karotažne krivulje CN-a

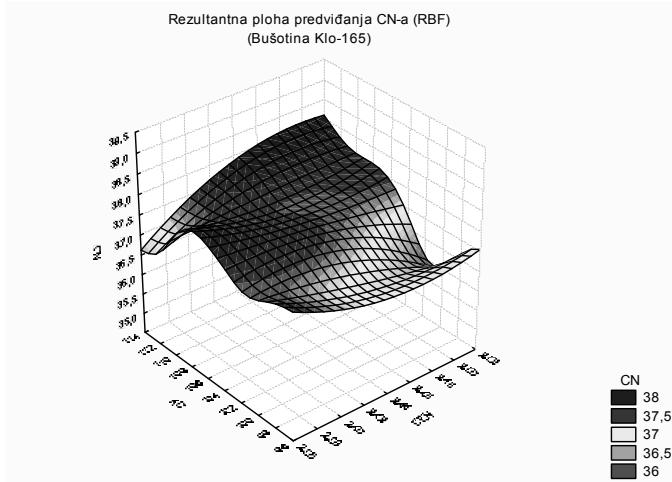
^a Svojstva neuronske mreže prikazana su tako da broj vrijednosti predstavlja broj slojeva u neuronskoj mreži. Prva i zadnja vrijednost predstavljaju broj neurona u ulaznome i izlaznome sloju, dok ostale vrijednosti prikazuju broj neurona u skrivenim slojevima.

^b Iznos pogreške prikazan je tako da 0 predstavlja 0 % pogreške, tj. 100 % uspješnosti, a iznos pogreške od 1 predstavlja 100 % pogreške, odnosno 0 % uspješnosti.

Iz iznosa pogrješke prikazane u **tablici 5.2** može se vidjeti da je RBF mreža manje uspješna u predviđanju od MLP mreže. To također potvrđuju vrijednosti na dijagramu razlika (**slika 5.5**), izgled rezultantne plohe na troosnomo dijagramu (iako je složene geometrije, nema mogućnost predviđanja maksimuma i minimuma vrijednosti – **slika 5.6**) i izgled same karotažne krivulje u odnosu na realnu i onu predviđenu MLP mrežom (**slika 5.4**).



Slika 5.5: Prikaz iznosa razlike vrijednosti predviđene RBF mrežom (na ordinati) za pojedini iznos stvarne vrijednosti (prikazana na apscisi)



Slika 5.6: Prikaz rezultantne plohe vrijednosti karotaže CN-a za RBF mrežu

5.3.3. Rezultati analiza neuronske mreže s postupkom poopćene regresije

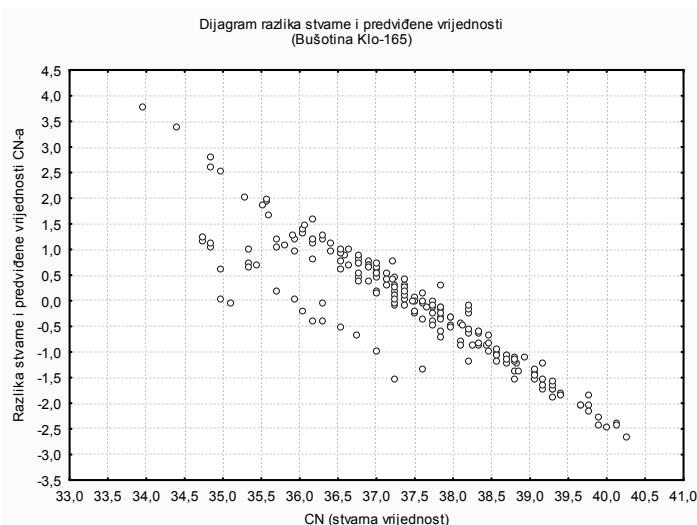
Najuspješnija GRNN neuronska mreža imala je, kao i RBF mreža, relativno visoke iznose pogreške (**tablica 5.3**). Unatoč manjoj uspješnosti uvježbavanja izdvojena GRNN mreža imala je prilično dobre vrijednosti predviđanja u odnosu na stvarne vrijednosti (**slika 5.4 i 5.7**), što je rezultat konstrukcije mreže kojom je moguće predviđati maksimume i minimume. Sposobnost predviđanja minimuma i maksimuma jasno se može vidjeti iz troosnoga dijagrama (**slika 5.8**).

Tip neuronske mreže i svojstva ^a	Pogrješka uvježbavanja ^b	Pogrješka selekcije ^b
GRNN 2-100-2-1	0,271277	0,288517

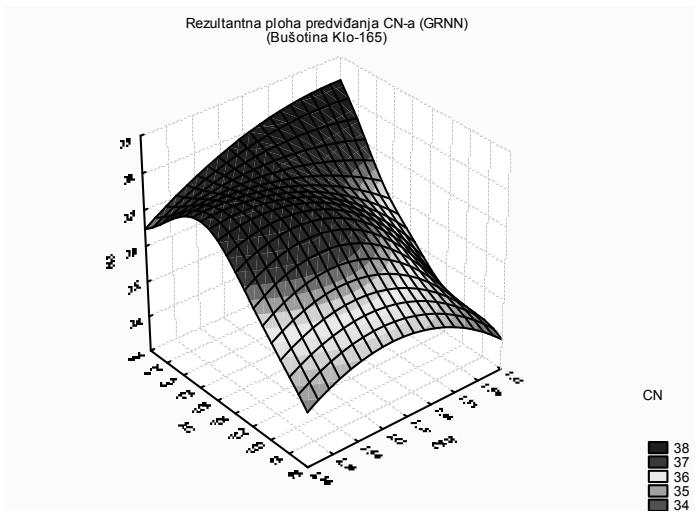
Tablica 5.3: Prikaz svojstava uvježbane mreže za predviđanje vrijednosti karotažne krivulje CN-a

^a Svojstva neuronske mreže prikazana su tako da broj vrijednosti predstavlja broj slojeva u neuronskoj mreži. Prva i zadnja vrijednost predstavljaju broj neurona u ulaznom i izlaznom sloju, dok ostale vrijednosti prikazuju broj neurona u skrivenim slojevima.

^b Iznos pogreške prikazan je tako da 0 predstavlja 0 % pogreške, tj. 100 % uspješnosti, a iznos pogreške od 1 predstavlja 100 % pogreške, odnosno 0 % uspješnosti.



Slika 5.7: Prikaz iznosa razlike vrijednosti predviđene GRNN mrežom (na ordinati) za pojedini iznos stvarne vrijednosti (pričekane na apscisi)



Slika 5.8: Prikaz rezultantne plohe vrijednosti karotaže CN-a za GRNN mrežu

5.4. REKONSTRUKCIJA KRIVULJA NEURONSKOM MREŽOM U POLJU STARI GRADAC-BARCS NYUGAT

Analize neuronskim mrežama u polju Stari Gradac-Barcs Nyugat prikazane su u dvama potpoglavljima. Prvi dio obuhvaća analize u bušotini Stg-3 intervala označenih kao „miocenski klastiti”, a drugi analize intervala „metavulkaniti”.

U oba poglavlja za analize su izdvojeni intervali od trideset metara za uvježbavanje (prvih i zadnjih deset metara) te provjeru uspješnosti neuronskih mreža (srednji interval). Neuronska mreža uvježbana je trima varijablama, no rezultantna ploha ipak nije prikazana troosnim dijagramima zbog preglednosti. Kao ulazne

variabilne korištene su karotažne krivulje AC-a, DEN-a i GR-a, a predviđena je vrijednost karotažne krivulje CN-a.

5.4.1. Rezultati analize podataka iz intervala „miocenski klastiti”

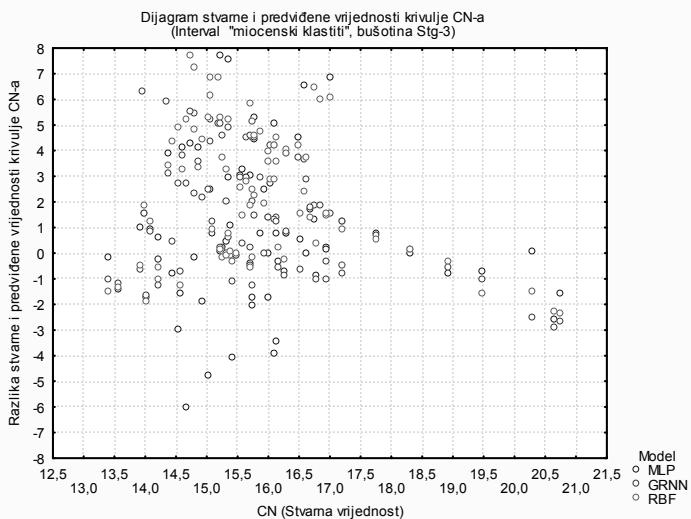
Odabrani interval pružao se u rasponu od –3530 do –3560 metara dubine. Uvježbano je nekoliko neuronskih mreža od kojih su za prikaz rezultata izabrane samo one najuspješnije (**tablica 5.4**). MLP mreža još se jednom pokazala kao najuspješnije uvježbana zbog najmanjih iznosa pogreške uvježbavanja i selekcije. Također, na zbirnome dijagramu razlika za sve mreže može se vidjeti da MLP ima najmanje razlike za većinu vrijednosti, no i najveća negativna i pozitivna odstupanja (**slika 5.9**).

Tip neuronske mreže i svojstva ^a	Pogrješka uvježbavanja ^b	Pogrješka selekcije ^b
MLP 3:3-4-6-4-1:1	0,064183	0,076466
GRNN 3:3-81-2-1:1	0,136259	0,207764
RBF 3:3-30-1:1	0,142624	0,151374

Tablica 5.4: Prikaz svojstava uvježbane mreže za predviđanje vrijednosti karotažne krivulje CN-a

^a Svojstva neuronske mreže prikazana su tako da broj vrijednosti predstavlja broj slojeva u neuronskoj mreži. Prva i zadnja vrijednost predstavljaju broj neurona u ulaznom i izlaznom sloju, dok ostale vrijednosti prikazuju broj neurona u skrivenim slojevima.

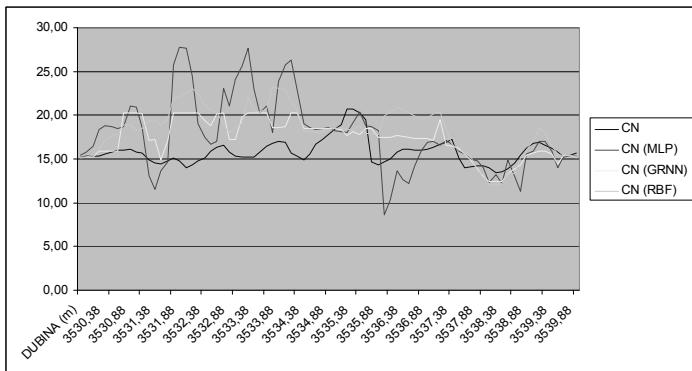
^b Iznos pogreške prikazan je tako da 0 predstavlja 0 % pogreške, tj. 100 % uspješnosti, a iznos pogreške od 1 predstavlja 100 % pogreške, odnosno 0 % uspješnosti



Slika 5.9: Prikaz iznosa razlike vrijednosti predviđene GRNN mrežom (na ordinati) za pojedini iznos stvarne vrijednosti (prikazane na apscisi)

Iako je prema vrijednostima pogrješaka selekcije i uvježbavanja MLP mreža bila najuspješnija, u intervalu predviđenome za provjeru uspješnosti neuronskih mreža imala je najveća odstupanja u intervalu od –3530 do –3535 metara (**slika 5.10**). U intervalu od –3535 do –3540 metara dobro odražava vrijednosti i trend stvarne krivulje. Prema **slici 5.10** najuspješnija neuronska mreža za predviđanje vrijednosti u intervalu „miocenskih klastita“ bila je GRNN neuronska mreža. Ona u prvome djelu intervala (od –3530 do –3535 metara) najbolje odražava vrijednosti stvarne krivulje kao i njezin trend. U drugome dijelu intervala „miocenskih klastita“

vrijednosti predviđene GRNN neuronskom mrežom također imaju najmanji odmak od one stvarne.



Slika 5.10: Odnos vrijednosti CN-a predviđenoga raznim neuronskim mrežama i stvarnih vrijednosti za interval od –3530 do –3540 metara (bušotina Stg-3)

5.4.2. Rezultati analize podataka iz intervala „metavulkaniti”

Odabrani interval bio je od –3810 do –3840 metara dubine. Prikaz najuspješnije uvježbanih neuronskih mreža dan je u **tablici 5.5**. Najuspješnije uvježbana mreža jest MLP mreža s trima skrivenim slojevima, dok GRNN, a posebice RBF mreža, imaju visoku pogrešku uvježbavanja i selekcije. Na dijagramu razlika (**slika 5.11**) također se može vidjeti kako vrijednosti predviđene MLP mrežom imaju manja odstupanja od onih predviđenih GRNN i RBF mrežom.

Tip neuronske mreže i svojstva ^a	Pogrješka uvježbavanja ^b	Pogrješka selekcije ^b
---	-------------------------------------	----------------------------------

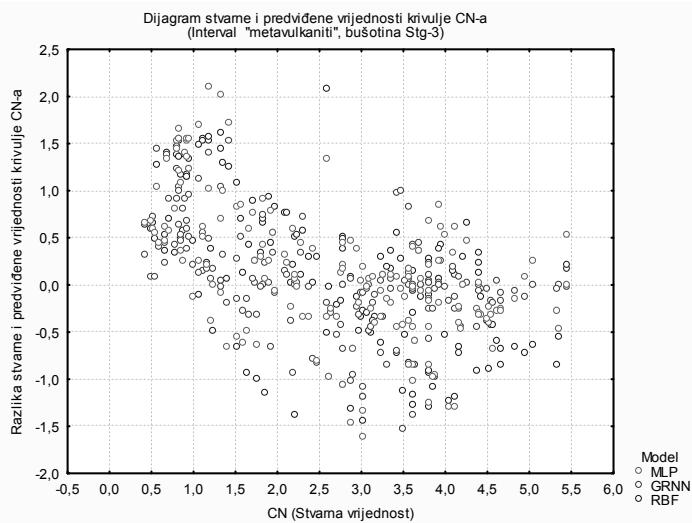
MLP 3:3-4-5-8-1:1	0,123758	0,184956
GRNN 3:3-80-2-1:1	0,220790	0,345607
RBF 3:3-13-1:1	0,416945	0,394645

Tablica 5.5: Prikaz svojstava uvježbane mreže za predviđanje vrijednosti karotažne krivulje CN-a

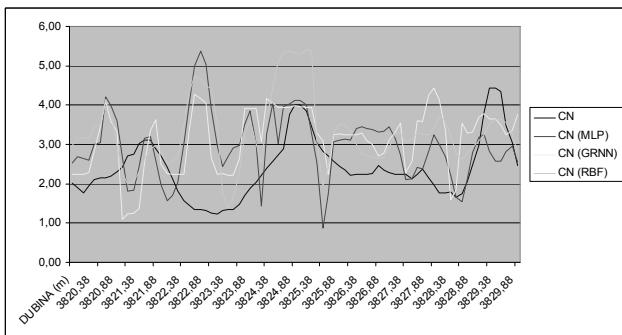
^a Svojstva neuronske mreže prikazana su tako da broj vrijednosti predstavlja broj slojeva u neuronskoj mreži. Prva i zadnja vrijednost predstavljaju broj neurona u ulaznom i izlaznom sloju, dok ostale vrijednosti prikazuju broj neurona u skrivenim slojevima.

^b Iznos pogreške prikazan je tako da 0 predstavlja 0 % pogreške, tj. 100 % uspješnosti, a iznos pogreške od 1 predstavlja 100 % pogreške, odnosno 0 % uspješnosti.

Uspješnost predviđanja neuronskim mrežama intervala od –3820 do –3830 metara dubine prikazana je na **slici 5.12**. Već iz vrijednosti pogreške uvježbavanja i selekcije, koje su prilično velike, moglo se zaključiti kako će predviđanje u tome intervalu za sve mreže biti manje uspješno nego u prošlima. Najboljom se ipak pokazala MLP mreža koja je u većini slučajeva uspjela pratiti trend karotažne krivulje CN-a uz iznimku prisutnu kod svih neuronskih mreža na vrijednostima iz intervala od –3822 do –3823 metra dubine.



Slika 5.11: Prikaz iznosa razlike vrijednosti predviđene GRNN mrežom (na ordinati) za pojedini iznos stvarne vrijednosti (prikazane na apscisi)



Slika 5.12: Odnos vrijednosti CN-a predviđenoga raznim neuronskim mrežama i stvarnih vrijednosti za interval od –3530 do –3540 metara (bušotina Stg-3)

5.5. REKONSTRUKCIJA KRIVULJA NEURONSKIM MREŽAMA U POLJU ĐELETOVCI

Rezultati analiza prikazani su zbirno za sve korištene vrste neuronskih mreža. Kao i kod analiza u polju Stari Gradac-Barcs Nyugat za prikaz uspješnosti koristili su se samo dijagrami i tablice s iznosima pogrešaka neuronskih mreža.

Izabrani interval bio je od -1000 do -1030 metara dubine bušotine Đt-42 koji obuhvaća ugljikovodicima nezasićen dio stijena „temeljnoga gorja”. Uvježbano je više neuronskih mreža od kojih su odabранe samo one najuspješnije. Varijable korištene za uvježbavanje bile su karotažne krivulje AC-a, DEN-a i GR-a, a predviđena varijabla bila je vrijednost karotažne krivulje CN-a.

Najuspješnije mreže, kao i njihovi parametri, prikazani su u **tablici 5.6**. Najuspješnije uvježbana neuronska mreža u ovome slučaju bila je RBF neuronska mreža, dok je MLP mreža imala najveće pogreške uvježbavanja u odnosu na ostale dvije. Posebno treba istaknuti da su uvježbane mreže imale najmanju pogrešku dotad u odnosu na analize u polju Kloštar i Stari Gradac-Nyugat. Uspješnost uvježbavanja također je prikazana na dijagramu razlika, gdje se vidi da neuronske mreže imaju male razlike između stvarnih i predviđenih vrijednosti, no minimumi i maksimumi vrijednosti CN-a izvrsno su predviđeni (**slika 5.13**).

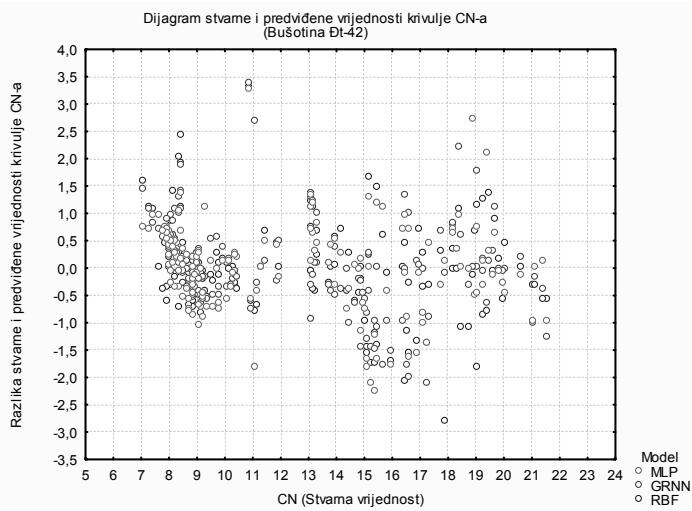
Tip neuronske mreže i svojstva ^a	Pogrješka uvježbavanja ^b	Pogrješka selekcije ^b
MLP 3:3-8-6-1:1	0,051508	0,062663
GRNN 3:3-80-2-1:1	0,043126	0,044439
RBF 3:3-26-1:1	0,039061	0,038555

Tablica 5.6: Prikaz svojstava uvježbane mreže za predviđanje vrijednosti karotažne krivulje CN-a

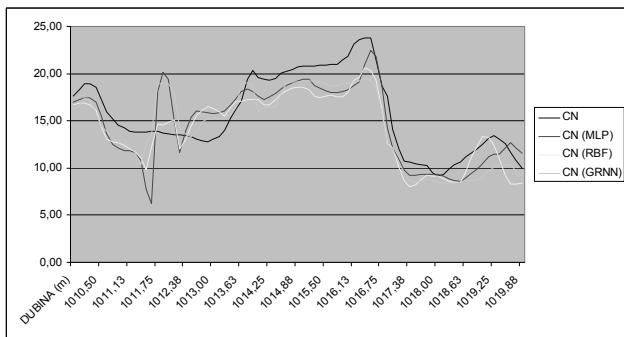
^a Svojstva neuronske mreže prikazana su tako da broj vrijednosti predstavlja broj slojeva u neuronskoj mreži. Prva i zadnja vrijednost predstavljaju broj neurona u ulaznome i izlaznome sloju, dok ostale vrijednosti prikazuju broj neurona u skrivenim slojevima.

^b Iznos pogreške prikazan je tako da 0 predstavlja 0 % pogreške, tj. 100 % uspješnosti, a iznos pogreške od 1 predstavlja 100 % pogreške, odnosno 0 % uspješnosti.

Uspješnost predviđanja neuronskim mrežama prikazana je na intervalu od -1010 do -1020 metara dubine bušotine Đt-42 (**slika 5.14**). Gotovo sve predviđene vrijednosti izvrsno prate stvarnu vrijednost krivulje CN-a, a najuspješnija mreža za predviđanje jest MLP neuronska mreža.



Slika 5.13: Prikaz iznosa razlike vrijednosti predvidene GRNN mrežom (na ordinati) za pojedini iznos stvarne vrijednosti (prikazane na apscisi)



Slika 5.14: Odnos vrijednosti CN-a predviđenoga raznim neuronskim mrežama i stvarnih vrijednosti za interval od –1010 do –1020 metara (bušotina Dt-42)

5.6. ZAKLJUČAK O REKONSTRUKCIJI KAROTAŽNIH KRIVULJA POMOĆU NEURONSKIH MREŽA

Ukupno je odabранo devet neuronskih mreža, tri od svake vrste, kojima su pomoću vrijednosti karotaže zvuka (AC), karotaže gustoće (DEN) i eventualno karotaže prirodne radioaktivnosti (GR) predviđene vrijednosti karotaže neutronske šupljikavosti (CN) iz istoga intervala.

Rezultati dobiveni analizama neuronskim mrežama na pojedinim lokacijama i litološkim sastavima jesu sljedeći:

- Sve vrste neuronske mreže uspješne su u predviđanju neutronske šupljikavosti, a najuspješnija je višeslojna mreža s povratnom informacijom (MLP);
- Najuspješnije predviđanje vrijednosti karotaže neutronske šupljikavosti bilo je na odabranome intervalu iz polja Đeletovc;
- Najmanje uspješno bilo je predviđanje vrijednosti krivulje neutronske šupljikavosti u intervalu „metavulkaniti” u polju Stari Gradac-Barcs Nyugat;
- Rezultati predviđanja klastičnoga intervala I. pješčenjačke „serije” bili su zadovoljavajući iako u ulaznome skupu nije korištena vrijednost krivulje prirodne radioaktivnosti (GR).

Ovim je istraživanjem još jednom prikazana primjenjivost neuronskih mreža u istraživanju ležišta ugljikovodika, u ovome slučaju u rekonstrukciji karotažnih krivulja, kao brzoga i jeftinoga alata koji s određenom pouzdanošću može uspješno rekonstruirati

dijelove pojedinih krivulja koje nedostaju.

5.7. LITERATURA

1. Atlas proizvodnih plinskih polja u Republici Hrvatskoj – verzija 7.2. (2005): Fond struč. dok., INA-Industrija nafte, SD Istraživanje i proizvodnja nafte i plina, Sektor za razradu, 243 str.
2. Brod, I. O. (1945): Geological terminology in classification of oil and gas accumulation. AAPG Bulletin, 29, 12, 1738–1755.
3. Brod, I. O. & Jeremenko, N. A. (1957): Osnovi geologii nafte i gasa. Izdanie tretie, Gostoptehizdat, Moskva.
4. Cvetković, M. & Bošnjak, M. (2009): Successfulness of different neural network algorithms for missing well log data prediction – Example from the Sava Depression. XIII. Congress of Hungarian geomathematics and the II. Congress of Croatian and Hungarian geomathematics, Morahalom.
5. Levorsen, A. I. (1956): Geology of petroleum. Freeman, 703 str., San Francisco.

POGOVOR

Nakon što je prikazano nekoliko različitih primjera uporabe neuronskih mreža na različitim vrstama podataka iz ležišta ugljikovodika u poljima Okoli, Kloštar i Beničanci, može se donijeti nekoliko općih zaključaka:

1. Gotovo svi podaci mogu se upotrijebiti kao ulaz u neuronske mreže;
2. Karotažne krivulje posebno su pogodne za analizu neuronskim mrežama zbog velikoga broja dostupnih podataka i visoke rezolucije;
3. Sve karte koje su interpolirane drugim metodama, a na njima su prikazane varijable ležišta nafte i plina, moguće je procijeniti i neuronским algoritmima;
4. Postoji nekoliko neuronskih algoritama, počevši od najpopularnije paradigme povratnoga postupka do naprednijih i specijaliziranih inačica poput radijalne funkcije, naprednoga povratnoga algoritma i drugih. Svaka upotreba zahtjeva određivanje najprimjerenije metode za obradbu odabralih podataka.

Prvi postupak u stvaranju primjenjive neuronske mreže predstavlja oblikovanje njezine arhitekture. Njime se utvrđuje broj slojeva unutar mreže (posebno broj skrivenih slojeva), određivanje veza unutar svakoga sloja i između slojeva, odabir aktivacijske funkcije postavljene uz svaku vezu te početnih težinskih koeficijenata pridruženih pojedinačnomu neuronu. Nadalje, svako uvježbavanje

neuronskih mreža predstavlja postupak kojim se traga za najprimjerenijim težinskim koeficijentima koji su, već u prvoj koraku, pridijeljeni pojedinačnim neuronima u slojevima.

Aktivirajući veze između neurona unutar i između slojeva, vrijednosti tih koeficijenata prilagođavaju se tijekom učenja. Vidljivo je kako veze između neurona i slojeva igraju vrlo važnu ulogu u radu mreže. Sve mreže opisane u ovoj knjizi bile su vrsta *potpuno povezanih mreža* (engl. *completely connected perceptrons*), što znači da je svaki neuron u prethodnom sloju povezan sa svakim neuronom u sljedećem sloju. No, arhitektura mreža može biti i malo drugačije posložena, pa tako kod *djelomično povezanih mreža* svaki neuron u prethodnom sloju nije povezan sa svim neuronima u sljedećem sloju. Kod *jednosmjernih mreža* veze (bilo potpune, bilo djelomične) su postavljene tako da informacije idu samo iz prethodnoga u sljedeći sloj (nema povratnoga postupka unutar jedne iteracije). Između tih slučajeva postoje razni varijeteti dvosmjernih i jednosmjernih veza, ovisno o tome događa li se učenje već unutar jedne iteracije, postoje li preferirane veze itd.

Možda je najvažniji mehanizam unutar neuronske mreže *aktivacijska funkcija* kojom se na kraju određuje hoće li izlaz nekoga neurona ili sloja postojati ili će signal biti „ugašen“. U svojoj biti, aktivacijska funkcija predstavlja pravilo učenja neuronskoga algoritma. Ako se vratimo na arhitekturu mreže opisnu preko slojeva, ulaz svakoga sljedećega sloja (osim početnom koji se ujedno naziva i „ulaznim“ za cijelu mrežu) zapravo je izlaz prethodnoga pomnožen s težinskim koeficijentom pridodanim izlazu

sloja ili neurona. Ako je takvih veza između slojeva više, kod svake od njih (obično svaka objedinjuje više „lokalno povezanih“ neurona) računa se takav umnožak.

Tada je moguće kod svake veze odrediti i prikladnu aktivacijsku funkciju, koja ovisno o vrijednosti izlaza određuje hoće li on biti ulaz za sljedeći sloj (neuron će biti aktivan) ili ne (bit će neaktivovan, tj. imat će vrijednost 0). Nekoliko je vrsta takvih funkcija kojima se donose odluke unutar umjetne mreže, a najčešća je *sigmoidna* funkcija koja je upotrijebljena u primjerima u ovoj knjizi. Sigmoidna funkcija još se naziva i *logistička*, a njezin čest varijetet jest *log-sigmoidna* funkcija. Zatim su tu još jednostavna *funkcija koraka*, pa složenije *signum funkcija*, *hiperboličko-tangentna*, *linearna*, *linearna funkcija s pragom* uz druge rjeđe upotrebljavane aktivacijske funkcije.

Ovisno o načinu učenja neuronske mreže, tj. o načinu na koji će predviđjeti vrijednosti, postoje dvije glavne vrste – neuronske mreže s nadgledanim učenjem i nenadgledanim učenjem. U radovima opisanim u ovoj knjizi korištene su samo mreže s nadgledanim tipom učenja koji podrazumijeva da se u postupku učenja neuronskoj mreži dodjeljuje određeni skup ulaznih podataka i odgovarajuće izlazne vrijednosti. Na temelju izlaza neuronske mreže proces učenja u novim je iteracijama poboljšavan korekcijom težinskih faktora pojedinačnih neurona. Način korekcije ovisi o upotrijebljenom pravilu učenja. Cilj je postupka da predviđena vrijednost bude što sličnije vrijednosti onoj iz ulaznoga skupa. Pravila nadgledanoga učenja koja se najčešće koriste jesu *delta*

pravilo, poopćeno delta pravilo i delta-bar-delta pravilo. Kod neuronskih mreža s nenadgledanim učenjem poznat je samo ulazni skup podataka, za razliku od onih s nadgledanim gdje je ulaznom skupu prirodan i skup izlaznih vrijednosti za potrebe uvježbavanja. Mreže s nenadgledanim tipom učenja koriste se uglavnom za prepoznavanje uzoraka u ulaznom skupu podataka, a najuspješnije pravilo učenja koje se primjenjuje je *Kohonenovo pravilo*.

U prikazanim analizama jasno je vidljiv potencijal analiza neuronskim mrežama u geologiji, a posebice u geologiji ležišta ugljikovodika. One su matematički alat koji vrlo brzo daje dovoljno dobre aproksimacije, tj. primjenjiva rješenja, kada ne postoji mogućnost linearne aproksimacije. To posebno vrijedi kod dovoljno velikih skupova ulaznih podataka kakvi su često dostupni u analizama ležišta nafte i plina.

Kazalo

Aktivacijska funkcija

(Activation function) 4, 7, 13, 15, 54, 84

Algoritam postupnoga opadanja

(Gradient descent algorithm) 15

Algoritam s povratnim postupkom

(Backpropagation algorithm, procedure) 11, 13, 14, 15, 53

Arhitektura potpuno povezanih perceptronova

(Completely connected perceptrons) 25

Brzina učenja (v. iznos učenja)

Delta pravilo

(Delta rule) 86

Delta-bar-delta pravilo

(Delta-bar-delta rule) 86

Elastični unaprijedjeni povratni algoritam

(Improved resilient propagation algorithm plus, Irprop+) 26

Iteracija

(Iteration) 1, 14, 16, 27-29, 32, 33, 40, 49, 53-55, 85

Izlazni sloj

(Output layer) 5, 6, 16, 18

Iznos učenja

(Learning rate) 10, 11, 14, 24, 26, 54

Iznos pogrješke

(Error rate) 8, 10, 25, 39, 41, 44, 66, 68, 69-71, 73, 74, 76, 78, 79

Koeficijent momenta (v. i momentni faktor)

(*Momentum coefficient*) **11, 14, 15, 54**

Kohonenovo pravilo

(*Kohonen's rule*) **86**

Korekcijski izraz

(*Correction term*) **10, 15, 85**

Log-sigmoidna funkcija

(*Log-sigmoid function*) **54, 85**

Lokalno prilagodljiva pravila učenja

(*Local adaptive learning rules*) **24, 26**

Momentni faktor

(*Momentum factor*) **11**

Mreža s postupkom poopćene regresije

(*Generalized regression neural network*) **18, 70**

Mreža s povratnim postupkom

(*Backpropagation network*) **12, 16, 17, 39, 49**

Mreža s radijalnom funkcijom

(*Radial basis function network*) **16, 17, 39**

Nadgledane mreže

(*Supervised networks*) **16, 17, 38, 85, 86**

Nenadgledane mreže

(*Non-supervised networks*) **16, 17, 85, 86**

Neuron, ljudski neuron

(*Neuron, human*) **2, 3**

Neuron, umjetni neuron

(*Neuron, artificial*) **4, 5, 12-14, 19, 84, 85**

Perceptron

(Perceptron) 12, 13, 25, 84

Pravilo učenja

(Learning rule) 24, 84, 86

Radijalna funkcija

(Radial basis function) 16, 17, 39, 48, 68, 83

Sigmoidna funkcija

(Sigmoid function) 7, 15, 53, 54, 85

Skriveni slojevi

(Hidden layers) 5, 6, 12, 13, 19, 25, 39, 40, 44, 53, 66, 68, 71, 74-76, 79, 83

Težinski koeficijent

(Weighting coefficient) 7-9, 11, 12-15, 19, 83-85

Transformacijska funkcija (v. aktivacijsku funkciju)

(Transfer function) 15

Učinak preuvježbavanja neuronske mreže

(Overtraining effect) 33

Ulazni sloj

(Input layer) 5, 6, 8, 9, 12, 16, 18

Višeslojna mreža

(Multiple layer perceptron) 14
